



Sveučilište
Sjever



University
North



Iva Rosanda Žigo
Nikolaj Lazić
Mirko Čubrilo

DIGITALNA HUMANISTIKA

Neka viđenja

Digitalna humanistika

NEKA VIĐENJA

Nakladnik

Sveučilište Sjever

Za nakladnika

Marin Milković

Urednica edicije

Jadranka Lasić-Lazić

Recenzenti

Damir Boras

Senada Dizdar

Lektura

Lea Golub

Grafička priprema

Mate Penava, Mirko Čubrilo

Tisak

Sveučilište Sjever, Centar za digitalno nakladništvo

Naklada

100 kom



ISBN 978-953-7986-57-5 (tisak)

ISBN ISBN 978-953-7986-58-2 (e-knjiga)

Ova knjiga je dana na korištenje pod licencom *Creative Commons*.

CIP zapis je dostupan u računalnome katalogu Nacionalne i sveučilišne knjižnice u Zagrebu pod brojem 001175803.


Iva Rosanda Žigo

Nikolaj Lazić

Mirko Čubrilo

Digitalna humanistika

NEKA VIĐENJA



KOPRIVNICA, 2023.

Sadržaj

Predgovor ix

Poglavlje 1

ULOGA TRADICIJE U OBLIKOVANJU
MODERNIH ZNANSTVENIH TIJEKOVA I

Humanističko računalstvo 12

Istraživačko ozračje u području humanističkog računalstva 15

Institucionalizacija humanističkoga računalstva 29

Humanističko računalstvo u kontekstu visokoga obrazovanja 33

*Problemi definiranja i pozicioniranja humanističkoga računalstva
kao samostalne discipline* 37

Poglavlje 2

DIGITALNA HUMANISTIKA 45

Okvir za definiranje digitalne humanistike
kao samostalne discipline 48

Terminološki problemi 54

Nestabilnosti teorijsko-metodološkoga okvira 56

Institucionalizacija digitalne humanistike 65

Digitalna humanistika u kontekstu visokoga
obrazovanja 69

Znanstveno-istraživački smjerovi digitalne
humanistike 73

Poglavlje 3

ZNAČAJ PODATAKA U HUMANISTIČKIM
ISTRAŽIVANJIMA 89

Prikupljanje podataka 91

Obrada i analiza teksta, jezika, zvuka i govora 93

Računalna obrada govora 98

Obrada podataka 105

Mentalne mape	123
Stilometrija	132
<i>Stilometrijska obilježja teksta i stilometrijske metode</i>	138
<i>Statističke metode na usluzi stilometriji</i>	141
Analiza glavnih komponenata (PCA)	142
Burrowsova metoda <i>Delta</i>	151
Labbéovska međutekstovna udaljenost	153
Burrowsov test <i>Zeta</i>	155
<i>A la reserche du Elena Ferrante</i>	158
<i>Problem lažnih vijesti</i>	164
<i>Stilometrijski problemi u vizualnom kontekstu</i>	167
<i>Algoritamske i logičke metode na usluzi stilometriji</i>	172
Formalne gramatike	174
L-sustavi	176
Regularni izrazi	182
<i>Gramatika regularnih izraza</i>	184
Logička strana umjetne inteligencije	191
<i>Sustavi simboličke logike</i>	199
Elementi pristupa računu sudova kroz sintaksu	205
<i>Aksiomatizacija računa sudova</i>	208
Elementi pristupa računu sudova kroz ssemantiku	211
Automatska dedukcija logičkih posljedica u okružju računa sudova	222
O računu predikata prvog reda	238
Neuronske mreže	263
<i>Temeljna arhitektura umjetne neuronske mreže: višeslojni perceptron</i>	264
Konvolucijske neuronske mreže	275
<i>Arhitektura konvolucijske neuronske mreže</i>	277
Literatura	287
Kazalo	295

Predgovor

Centar za razvoj digitalnih kompetencija i tehnologija e-učenja Sveučilišta Sjever kao jednu od važnih aktivnosti u svom programskom djelovanju ističe praćenje aktualnih tema iz širokoga područja informacijsko-komunikacijskih tehnologija i njihova utjecaja na suvremene znanstvene tijekove kroz publiciranje knjiga i radova znanstvenika iz nacionalnoga istraživačkoga miljea.

Cilj je takvim publikacijama obogatiti hrvatski znanstveni prostor istraživanjima koja držimo važnima, ali jednako tako u nas još uvijek deficitarnima.

Ideja, da nakon knjige *Digitalna transformacija: pomaci u obrazovanju*, započnemo niz koji će pratiti proces promjena u znanosti i obrazovanju u digitalno doba, urodila je knjigom koja je pred vama. Digitalna transformacija definirala je što znače digitalne promjene, a ova knjiga ima zadaću otvoriti pitanja, iznijeti mišljenja što se podrazumijeva pod humanističkim računalstvom i digitalnom humanistikom. Postavljanje pitanja, dakako traži i odgovor. Za sada odgovor nije jednoznačan, iz razloga što je i područje o kojemu se govori vrlo široko i različito u mogućnostima primjene računalnih alata. Tako odgovori i razmišljanja predstav-

ljeni u ovoj knjizi slijede logiku kojom se u prvom dijelu, kroz svojevrsnu metarazinu čitatelja nastoji uvesti u područje, dok se svakim novim poglavljem ulazi sve dublje te se detaljnije nastoje opisati pojedini problemi, ali i pokazati različite mogućnosti koje računalni alati danas pružaju humanističkim istraživačima.

Stoga, djelo koje je pred vama pokazuje ozbiljnost naših namjera i želju da u tom nastojanju budemo aktualni i kontinuirani. Jer, želimo li ići u korak s tehnološkim progresom, što više nije izbor, tada se ideja uključivanja digitalne transformacije u sva područja znanosti, umjetnosti i djelatnosti pojavljuje kao samorazumljiva. Novi „zeleni“ horizont za humanističke znanosti otvorila je digitalizacija sadržaja papirnog vremena. Zajedno s ogromnim kapacitetom pohrane i računalnom snagom, alatima kojima možemo predstaviti duhovne zapise humanističkih znanosti i to novim obrascima i vezama koje inače ne bismo pronašli ili ispitali bez korištenja računalne tehnologije, otvaramo poglavlje koje se nerijetko označava sada već popularnom sintagmom–*digitalna humanistika*. Ako je računalna tehnologija naša sudbina, onda je digitalna humanistika stvarnost i u našem znanstvenom okruženju. Ako smo prihvatili činjenicu kako danas niti u jednom području ne možemo bez računalne podrške, onda smo prihvatili i humanističko računalstvo i digitalnu humanistiku, pa je motivacija autora da konačno i u domaćoj znanosti predstave nove smjerove u humanističkim istraživanjima posve opravdana. Prvenstveno iz razloga što je riječ o području koje je u međunarodnim okvirima već dobro poznato i bogato literaturom, ali i konkretnim istraživačkim rezultatima i primjenom u obrazovnom procesu.

Držimo kako je nužno ukazati na činjenicu da je primjena različitih računalnih alata u svim područjima znanosti postala nezaobilazna, a suvremeni inozemni trendovi pokazuju kako ni humanistika nije imuna na ove evidentne promjene. Svjesni činjenice kako živimo u vremenu promjene paradigme koja istodobno zahvaća sva znanstvena područja, detektirali smo kako je od iznimne važnosti domaćoj zajednici približiti teme, probleme i mogućnosti koje nove tehnologije uvode u istraživačko područje humanistike.

Ideja je, kroz prikaz korištenja gotovih računalnih alata pokazati što se sve može koristiti u istraživačkim postupcima, ali isto tako ukazati da svako posebno istraživanje i korištenje alata zahtjeva njegovu prilagodbu upravo za tu namjenu. Poznavanje nekog od programskih jezika postaje tako zahtjev i za humanističke znanstvenike. U tom kontekstu predstavljene su i teme koje se obrađuju u knjizi, one pružaju izazov i priliku prevladavanja nelagode zbog nepoznavanja alata, kao i podozrivost i frustracije prema računalnim metodama u humanističkom području.

Izbor tema obrađenih u knjizi izlaže pregled razvoja, a s druge strane pruža neophodan poticaj te izborom primjera potiče na samostalno putovanje u svijet tehnologije i računala. Bilo bi pogrešno reći da u humanističkom području nismo koristili računalne alate te da ne možemo bez njih, ali je zasigurno točno da s njima možemo puno više i brže.

Knjiga „Digitalna humanistika....“ rezultat je rada troje autora koji se razlikuju svojim obrazovanjem i uopće znanstvenim habitusom, te osim što pokazuju tri različita pristupa u razumijevanju važnosti ulaska računala u humanističko područje znanosti, ukazuju i na jednu od temeljnih karakteristika suvre-

mene znanosti uopće. Riječ je, dakako, o interdisciplinarnosti i multidisciplinarnosti, odnosno o nužnoj znanstveno-istraživačkoj suradnji znanstvenika različitih područja znanosti koji jedino zajedničkim radom i suvislim dijalogom mogu doprinijeti kvaliteti znanstvenih projekata i rezultata istraživanja.

Nadalje, ovom se knjigom otkriva i svijest o tome kako tehnologije ruše tradicijom postavljene granice i kako metode koje su desetljećima bile rezervirane isključivo za pojedina područja znanosti postaju danas sveprisutne. Promjene u mogućnostima i načinima predstavljanja znanja, kao i promjene na području medija koji su nekada predstavljali temeljne izvore za humanistička istraživanja postavljaju pred znanstvenike ovoga područja posve nove zahtjeve koji se u prvom redu odnose na primjenu računalnih tehnologija u istraživačkom procesu.

Knjiga nas povijesno uvodi u područje kroz rane radove entuzijasta iz područja računalne humanistike, donosi potom osvrt na prve konferencije i rasprave o ovom području te ukazuje na niz i danas aktualnih pitanja. Prvom, već spomenutom knjigom u ovom nizu, onom iz 2021. godine, definirali smo značaj digitalnih promjena, dok ovo djelo ima zadaću otvoriti niz pitanja te ukazati na mnoštvo katkada posve različitih mišljenja u kontekstu pojmo-va *humanističko računalstvo* i *digitalna humanistika*. Autorima nije bio cilj ponuditi odgovore, nego u prvom redu ponuditi na hrvatskom jeziku knjigu te ukazati na promjene koje su u međunarodnom znanstvenom okružju prepoznate u humanističkom području već nekoliko desetljeća. Jednako tako, cilj je ukazati na neke alate, pokazati njihove mogućnosti, ali i upozoriti kako je u nemalom broju slučajeva brojne alate potrebno prilagoditi specifičnos-

tima svakog pojedinoga istraživačkoga projekta. Put koji se otvara ovim djelom jednostavno je put koji poziva na zajedničko kretanje ljudske i umjetne inteligencije prema nekim novim i drugačijim znanstvenim izazovima.

Da bi razbili „zazor” od računalnih metoda, „formula“ i „formalizacija“, koji su svatko sa svoga motrišta uočili tijekom dugih godina podučavanja na svim razinama sveučilišnih studija, autori nizom primjera pokazuju kako bez apstraktnog mišljenja i stvaranja formalnih modela (teorija) stvarnosti znanost i tehnologija jednostavno nisu zamislivi. Shvaćanje kako znanost i tehnologija nisu zamislivi bez apstraktnog mišljenja i napor da se neutralizira kritičnost naspram humanističkog „zazora“, evidentan je u mnoštvu primjera koji bi trebali pokazati kako nelagodu bilo koje vrste možemo i moramo prevladati. Na ovom se mjestu tako otkriva, govorimo li o znanstvenom istraživanju i primjeni računalnih metoda, povjerenje koje autori iskazuju prema otvorenosti znanstvenika u području humanističkih znanosti prema njihovom prihvaćanju, usvajanju i korištenju, na dobrobit kako samih humanističkih znanosti, tako i znanstvenika samih.

U tom je kontekstu osobito zanimljivo četvrto poglavlje koje Mirko Čubrilo započinje pričom o događanjima u dvorani za plenarne sjednice Munchenskog sajma na godišnjoj konferenciji tvrtke NVIDIA 2018. godine, kroz koje nas slijedom vodi sve do najnovijih postignuća u primjeni neuronskih mreža, dubokog učenja, sustava simboličke logike i formalnih jezika, ukazujući ne samo na potencijal njihova korištenja u kontekstu humanističkih znanosti, već i njegovu nužnost.

Teme koje autor dotiče dolaze iz riznice umjetne inteligencije, koja s obzirom na istraživačke metode koje koristi u rješavanju problema počiva na dva stupa. Temelji jednoga ponajviše su algoritamske (numeričke i statističke) metode, a drugoga metode simboličke logike, teorije formalnih gramatika i općenito formalizacije svih vrsta. Od izloženih tema prvima pripadaju stilometrija i neuronske mreže, a od drugih elementi mentalnih mapa, deduktivnih sustava, formalnih gramatika, regularnih izraza, logičkih programskih jezika i logičkog programiranja. U odnosu prema čitatelju, izlaganje izabranih tema prvenstveno je motivacijsko, što izložene primjere ograničava u vrsti, broju i složenosti. Bogat popis literature čitatelja upućuje na daljnja samostalna istraživanja.

Autor se u dijelu izlaganja poduhvatio i suradnjom sa ChatGPT-om kao jednim od golemih jezičnih modela koji već sada, u ranoj fazi razvoja, iskazuje izuzetno razumijevanje govornog jezika, s neizmjernim mnoštvom njegovih semantičkih finesa i sposobnost davanja odgovora (rješavanja problema) na mnoštvo pitanja i zahtjeva, pa neka ostane zapisano da je ovo prva knjiga na hrvatskom jeziku s dokumentiranom konverzacijom s tim sustavom.

Raspon tema unutar ovoga interdisciplinarnoga područja namjerno je predstavljen upravo na ovaj način, s ciljem dobivanja općega znanja o ovoj uzbudljivoj disciplini. Riječ je, dakle, o prvom izdanju dok će svako drugo, a o kojima se već lagano razmišlja, biti usmjereno prvenstveno na primjenu konkretnih računalnih alata i metoda u kontekstu konkretnoga predmeta istraživanja.

Uloga tradicije u oblikovanju modernih znanstvenih tijekova

Podjela znanosti na znanstvena područja, polja i grane osim što regulira znanstveno djelovanje u administrativnom, formalno-pravnom smislu zanimljiva je i iz razloga što se svakim pokušajem grupiranja i sistematizacije različitih pojava ujedno ukazuje i na prirodni tijek razvoja znanosti, kao i na međusobne razlike i sličnosti između različitih znanstvenih područja. Svrha je razvrstavanja da se u *mnoštvu raznih vrsta napravi red i preglednost. No, razvrstavanjem svih predmeta prema jednoj osnovi ne bismo mogli zadovoljiti sve zahtjeve koji se u konkretnom slučaju traže. Zbog toga se predmeti i pojmovi grupiraju po sličnosti i međusobnim vezama* (Žugaj 1989, str. 258). Povijesni razvoj klasifikacije znanosti ukazuje na postajanje triju glavnih faza pa je tako prvoj fazi, onoj iz antičkoga doba svojstvena jedinstvenost znanosti. Filozofija je u to doba bila jedina znanost, funkcionirala je kao „znanost nad znanostima“ te je obuhvaćala sva ljudska znanja o prirodi, društvu i mišljenju. U razdoblju od 15. do 18. st., dakle, tijekom druge razvojne faze započinje proces diferencijacije znanosti pa se od filozofije odvajaju specijalne znanosti; prvo matematika, potom mehanika, zatim astronomija, a onda i fizika, kemija, biologija, geologija, sociologija i psihologija. Početkom 19. st. započinje treća faza koju karakterizira još naglašenija diferencijacija, ali istodobno i integracija pojedinih znanstvenih disciplina. Iz toga proizlazi kako je razdvajanje znanosti praćeno konstantnim povezivanjem kontinuirani, dijalektički proces (isto., str. 262., Zelenika 2006, str. 14). Prema tome, niti jedna klasifikacija znanosti nije konačna, *to je*

prolazno stanje spoznaje prirode, koje vodi do više spoznaje, do nove klasifikacije prirode i znanosti kao skupa znanja o njoj (Žugaj 1989, str. 275).

Svjesni činjenice kako klasifikacija nije nimalo jednostavan zadatak, smatramo kako bi njezin smisao trebalo koncentrirati upravo na jačanju uzajamnih veza između različitih područja, a razvoj suvremene znanosti razumjeti prije svega u kontekstu njezinih interdisciplinarnih, multidisciplinarnih, transdisciplinarnih i pluri-disciplinarnih karakteristika. Slijedom navedenoga razmišljamo i o središnjem pojmu naše knjige koji, kako ćemo vidjeti, unatoč velikom broju objavljenih znanstvenih rasprava i komentara još uvijek izmiče jedinstvenom, jasnom klasifikacijskom određenju. Na problematiku jedinstvenoga određenja digitalne humanistike (DH¹) dodatno utječe fleksibilnost i nestalnost teorijskoga okvira, metodoloških postupaka, kao i različitost tehnologija istraživanja. I dok, kako to dobro primjećuje Kuhn (2013), istraživačke procese prirodnih znanosti nerijetko karakterizira, takozvani stabilan model, među znanstvenicima društvenoga područja znanosti često *dolazi do neslaganja o prirodi legitimnih znanstvenih problema i metoda* (str. 10). Navedenu Kuhnovu misao svakako valja nadopuniti i zajednicom humanista koju, bez obzira na širinu problema koji ulaze u djelokrug njihove znanstvene okupacije ili baš upravo iz toga razloga, nerijetko povezuju posve specifične, ali i fluidne metode istraživanja.

Unatoč, naime, tom toliko često spočitavanom problemu legitimnosti istraživačkih metoda moramo ostati svjesni iznimne

¹ Pojmove *digitalna humanistika* i *humanističko računalstvo* često ćemo, a radi jednostavnosti izričaja, označavati kraticama – DH i HR.

tradicije koja, u povijesti razvoja znanosti i akademskoga života uopće, pripada humanistici. Riječ je o području koje je otvorilo puteve brojnim drugim znanstvenim disciplinama, a kojem su do 19. st. uzor predstavljale upravo prirodne znanosti. Međutim, važan korak u institucionalizaciji humanistike odnosi se na postupni proces specijalizacije, dakle, proces koji se odvijao tijekom modernizacije srednjovjekovnih sveučilišta, a upravo do sredine 19. st., *dolaskom pune industrijalizacije i izgradnjom javnog školskog sistema i javnih univerziteta, humanistika je dobila njen današnji oblik. To je bilo doba u kome su se književnost, filozofija i klasika odvojile od fizičkih i prirodnih nauka* (Tabak 2017, str. 20). Jednako tako, riječ je i o području koje predstavlja jednu od temeljnih okosnica razvoja paradigme tradicionalnoga sveučilišta, a koja potječe još od njemačkih i francuskih sveučilišnih koncepcija 18. i 19. st. i koja još uvijek čuva, barem u kontekstu europskih i najboljih svjetskih sveučilišta (Harvard, Stanford) ideju o podjeli znanosti u dvije velike skupine. Riječ je o humanističkim znanostima (duhovnim znanostima, *Geisteswissenschaften*) kojima je Humboldt dodao sociologiju, političku ekonomiju i druge znanosti pa ta skupina sadrži i društvene znanosti, te o prirodnim znanostima ili prirodoslovlju (*Naturwissenschaften*) (Žugaj 1989, str. 263). Humboldtova ideja sveučilišta tako pretpostavlja dobro temeljno obrazovanje (povijest, politika, kultura, jezik, religije), znanstveno obrazovanje, tj. obrazovanje o razumijevanju načela znanosti, te obuku za pojedina zanimanja. Navedeno predstavlja tri temeljna funkcionalna stupa (moć rasuđivanja, povijesno znanje, znanje načela) koja se orijentiraju obrazovanju pojedinca sposobnoga, zahvaljujući osobnoj i profesionalnoj slobodi, znanju

i kreativnosti doprinijeti napretku društva. Obrazovanje tako, prema Humboldt, pretpostavlja *napor čovjekove volje da u sebi postane slobodna i neovisna, da se svijet poveže i obujmi sa sobom* (Kokić 2013, str. 426).

Slijedom navedenoga, gotovo je nemoguće ideju o znanju i obrazovanju ne povezati s toliko naglašenom antropocentričnom komponentom kojom su prožete društveno-humanističke znanosti i iz kojih, u konačnici, velikim dijelom i izrasta koncept tradicionalnoga razumijevanja visokoga školstva. Naravno, danas svjedočimo različitim prijedorima u shvaćanju znanosti, kao i u shvaćanju načina na koje bi moderno sveučilište trebalo organizirati. Ponekad nam se čini kao da se razvoj tehnologija i nas samih odvijao nekim odvojenim putevima pa smo, ni ne znajući posve zašto, skloni tradicionalno znanje kategorizirati nepotrebnim, katkada čak i nepoželjnim. Takvo je stajalište u potpunosti pogrešno pa iz toga elementarnoga nerazumijevanja značaja koje svakom pojedinom području znanosti pripada u odnosu na znanost u cjelini, i dolazi do favoriziranja određenih disciplina. Upravo je iz toga razloga važno ojačati sponu i potaknuti komunikaciju među istraživačima različitih znanstvenih područja koja u konačnici i može osigurati moderno razumijevanje znanosti i utjecati na razvoj društva budućnosti. Prema tome, moderna znanost ne raskida s tradicijom, upravo suprotno, ona je svjesna vlastitih ishodišta baš kao što je i svjesna činjenice kako je mijena jedno od njezinih temeljnih svojstava.

Stoga je za razumijevanje današnjih tijekova svojstvenih humanističkim znanostima važno prisjetiti se njihove prošlosti, statusa kojega su one tijekom povijesti uživale, ali i faza kroz

koje su tijekom vlastitoga razvoja prolazile. Humanistici je u prošlosti blizak pojam *duhovnih znanosti*, dakle, pojam koji je u uporabu ušao prvenstveno zahvaljujući J. S. Millu, odnosno prevoditelju njegovu *Logike*, a u kojoj su skicirane mogućnosti primjene induktivne logike na ono što on naziva *moral sciences* (Gadamer 1978, str. 29). Nije, naime, Mill imao namjeru *duhovnim znanostima* priznati specifičnu, njima svojstvenu logiku. Upravo suprotno, nastojao je pokazati kako je induktivna metoda koja je u temelju empirijskih znanosti, jednako tako relevantna i u ovom području. Na taj se način priklonio engleskoj tradiciji čiju je značajnu formulaciju iznio Hume u uvodu za *Raspravu o ljudskoj prirodi* 1739. godine u kojoj ističe kako se i *u nauci o moralu radi, navodno, o tome da se spoznaju istoobličnosti, pravilnosti, zakonitosti koje omogućavaju predviđanje pojedinih pojava i tokova. Ovaj cilj se, istina, ni u oblasti prirodnih nauka ne postiže svugdje na isti način. No, razlog je isključivo u tome što se ne može svuda dobiti dovoljno podataka iz kojih bi se dale spoznati istoobličnosti* (isto., str. 29-30). Iz navedenoga se može izlučiti upozorenje o postojanju individualnih specifičnosti problema istraživanja unutar istoga znanstvenoga područja. Gadamer je upozoravao na fleksibilnost, a ne na isključivo i slijepo praćenje neke općeprihvaćene metode u procesu istraživanja. Specifičnosti problema i metoda istraživanja izdvojio je kao signifikantni trenutak humanističkih znanosti.

Indukciju nije uvijek i isključivo moguće primijeniti iz razloga što se, kako upozorava, istinski problem *duhovnih znanosti* ne može ispravno shvatiti u slučaju da se mjeri isključivo mjerilima prirodnih znanosti. *Pojedinačno ne služi kao potvrda neke zakonitosti iz koje bi u praktičnoj primjeni bile moguće prognoze. Naprotiv, njezin*

je ideal da se sama pojava razumije u njezinoj jedinstvenoj i povijesnoj konkrekciji. Pritom nije važno koliko tu djeluje opće iskustvo: cilj nije da se oba opća iskustva potvrde i prošire da bi se došlo do spoznaje nekog zakona, recimo, kako se uopće razvijaju ljudi, narodi, države, već da se razumije kako ovaj čovjek, ovaj narod, ova država jest ono što je postala – uopćeno rečeno: kako je moglo doći do toga da je tako (isto., str. 30). Drugim riječima, cilj *duhovnih znanosti* nije potraga i otkrivanje općosti, već skretanje pažnje i važnosti u procesu istraživanja na jedinstvenost pojava, potraga za njezinim izvorima i uzrokom. Iz navedenoga je, stoga, posve razumljiva Gadamerova misao prema kojoj *duhovne znanosti* nikako nisu i ne mogu biti podređene prirodnim znanostima. U *duhovnom slijedu njemačke klasike one su, naprotiv, razvijale gordi osjećaj vlastite vrijednosti, osjećaj da su istinski zastupnici humanizma* (isto., str. 34). Epoha njemačke klasike pojmu humaniteta dala je posve novi sadržaj, što je dovelo do njegova približavanja pojmu *obrazovanja* koji je postao jednim od temeljnih elemenata u kojem su *duhovne znanosti* egzistirale tijekom 19. stoljeća. Nije, stoga, za čuditi da Gadamer kao vodeće humanističke pojmove izdvaja upravo *obrazovanje*, te mu pridodaje još i *sensus communis*, *moć suđenja* i *ukus*.²

² U kontekstu *sensus communis* kao polazište uzima spis *De nostri temporis studiorum ratione*, autora G. B. Vica iz 1947. godine, u kojem se autor upušta u obranu humanizma pod utjecajem jezuitske pedagogije. Ovaj pedagoški manifest, upozorava Gadamer, utemeljen je na starim istinama; u njemu poziva na *sensus communis*, na zajedničko čulo i na humanistički ideal *eloquentiae*, dakle na one elemente koji su postojali još i u antičkom pojmu mudrosti. Ono „dobro govoriti“ je odvajkada u sebi dvoznačna formula i ni u kom slučaju nije samo retorički ideal. Ono podrazumijeva i kazivanje pravilnoga, to znači istinitoga, a ne samo: vještinu govora, vještinu nešto dobro reći (Gadamer 1978, str. 45). Nadalje, važno je istaknuti kako je u njemačkom 18. st. pojam *sensus communis* u najužoj vezi s pojmom *moć suđenja*, a koji je zapravo u najužoj

Postepena transformacija ranog humanizma u discipline koje čine današnje humanističko područje događala se, izuzev gore spomenute modernizacije školstva i sveučilišta, u kontekstu razvoja uredničkih praksi uključenih u *renoviranje čitavog korpusa radova iz klasične antike, koja su bila očuvana tokom srednjeg vijeka u grčkim i arapskim rukopisima u bizantskim i islamskim centrima učenja* (Tabak 2017, str. 18). Razvojem izdavačke industrije koja je podržavala zainteresiranu javnost i time pridonijela jačem zanimanju za sekularne, znanstvene i literarne teme, kao i razvoju standardnih jezika i književnih formi, proširio se horizont humanističkih izraza poezijom Dantea, Petrarce, kao i s prijevodima klasičnih tekstova s latinskog, grčkog, itd. Dakle, izgradnja humanistike bila je usko vezana uz klasičnu filologiju, odnosno uz discipline kao što su arheologija, povijest umjetnosti, lingvistika. Početkom 20. stoljeća, u anglofonom kontekstu, odsjeci za književnost bili su prvo oformljeni kao odsjeci orijentirani istraživanju srednjovjekovlja i renesanse, a tek su se kasnije orijentirali na modernu filologiju. U tim je počecima fokus primarno bio na studijima jezika i retorike, a tek su kasnije odsjeci organizirani na pojedine nacionalne književnosti i medije.

No, jedan od ključnih trenutaka u razvoju humanističkih znanosti jest onaj u razdoblju nakon Drugog svjetskoga rata

vezi s onim što se podrazumijeva pod *zdravim ljudskim razumom* (isto., str. 57). Kant je upravo pojam *ukusa* učinio temeljem svoje kritike moći suđenja te bi ga se prije moglo okarakterizirati *moralnim*, a tek onda *estetskim* pojmom. *On opisuje ideal pravog humanizma (...)* Na „*duhovno lijepo*“ je *upotreba ovoga pojma sužena tek kasnije* (isto., str. 62). Prema tome, ukus jest jedan od načina spoznaje, ne predstavlja ništa privatno, već je riječ o društvenom fenomenu prvoga reda (isto., str. 63)

kada se pojavljuju klasično obrazovani filolozi, kao što su Erich Auerbach, Leo Spitzer i René Wellek koji su zauzeli vodeće pozicije na američkim sveučilištima (Burdick i sur. 2012, str. 6). Do sredine 20. stoljeća, moderna istraživačka sveučilišta karakterizirala je segmentacija odsjeka pa su tako primjerice odvojeno funkcionirali odsjeci za prirodne i društvene znanosti. S vremenom se sve više počelo govoriti o takozvanoj krizi humanističkih znanosti, kao i o njihovu nepovoljnom položaju u odnosu na ostala znanstvena područja. No, problematici *krize* u humanistici valja pristupiti s oprezom i to prvenstveno iz razloga što se o njoj raspravlja u različitim izvorima već više od jednoga stoljeća pa je i sama prošla kroz različite transformacije. U slučaju da se položaj humanistike u odnosu na druga područja i ocjenjuje nepovoljnijim, držimo kako je potrebno iznaći razloge takova stanja. Jer, činjenica jest da u kontekstu suvremenih humanističkih znanosti, a posebno se to odnosi na nacionalni istraživački prostor, aktivni istraživači još su uvijek oni obrazovani mahom u kontekstu tradicionalnih znanja. Iz toga proizlazi kako je upravo na obrazovnom sustavu veliki dio tereta u iniciranju promjena s kojima definitivno valja čim prije započeti. Jednu od takvih promjena može ponuditi upravo DH koja nudi jedan posve drugačiji pristup; na sadašnjicu gleda kao na priliku obnove značajnih humanističkih projekata te se kreće k demonstraciji doprinosa suvremene humanističke znanosti novim načinima oblikovanja znanja, omogućenoga umreženim, digitalnim okruženjem (isto., str. 7).

Dvije su temeljne točke koje u kontekstu humanističkih znanosti, i to od njezinih početaka, predstavljaju okosnicu gotovo svih istraživanja. S jedne strane, riječ je o čovjeku kao središnjem

mjestu u kulturi i umjetnosti, tj. kao središnjici cjelokupnoga postojanja. S druge strane, humanistika je od samih početaka usko povezana i s tehnologijama. Dovoljno je prisjetiti se samo tehnologije tiska koja je omogućila standardizaciju i širenje humanističkog kulturnog korpusa, te je otvorila put modernim humanističkim znanostima kakve poznajemo danas. Tehnologije imaju dvostruku ulogu, one s jedne strane osiguravaju korpus za provođenje istraživanja, a s druge osiguravaju moćne alate za unaprjeđenje provođenja istraživanja pa samim time doprinose i kvaliteti rezultata istraživanja. Nedvojbeno, tehnologije su potaknule interdisciplinarnost i izgradnju znanstvenoga ozračja u kojem se brišu stroge granice između različitih područja znanosti, ozračja u kojem su rasprave oko pokušaja određenja neka „znanstvenije“ discipline nauštrb one druge, „manje“ važne postale besmislene i pokazuju nerazumijevanje promjene paradigme kroz koju danas prolaze sva znanstvena područja. Dakako, navedeno nas navodi na misao kako će se možda u nekom skorom vremenu morati dogoditi i reorganizacija postojeće podjele znanstvenih područja, polja i grana, a problemi koje iznosimo u ovoj knjizi sasvim jasno ukazuju upravo na te mogućnosti. Nove tehnologije pritom držimo inicijatorima tih promjena, upravo su one otvorile put uspostavi dijaloga među znanstvenicima različitih područja znanosti, utjecale na kvalitetu istraživanja, te su potaknule misao o nekim novim, drugačijim putevima kojima treba krenuti.

Mišljenja smo kako se u ovom trenutku ne moramo pa čak i ne smijemo sputavati ograničenjima koja proizlaze iz klasifikacije znanstvenih područja. Jednako tako, ne smijemo opsesivno tražiti „pretinac“ u koji ćemo neko područje istraživanja smjestiti kako

bi smo naprosto zadovoljili formalno-pravne i administrativne propise. I bez obzira što smo nerijetko takvo što i primorani činiti, ovom smo knjigom željeli napraviti iskorak i ne podleći unaprijed zadanim ograničenjima. Upravo suprotno, nastojali smo pokazati kako dijalog „različitih“ može pridonijeti iznimno važnim suradnjama, projektima, znanstvenim publikacijama i sl., i kako se na taj način može učiniti iskorak i pridonijeti znanstvenom napretku. Humanističke znanosti uistinu prolaze kroz različite promijene, one uključuju istraživačke prakse, modele financiranja, ulogu kreativnoga izričaja, infrastrukturne karakteristike, interdisciplinarni sentiment i potrebu za snažnim povezivanjem humanista koji svoje snage moraju usmjeriti procesu proizvodnje znanja, ali i samom proizvodu. Jedan od značajnijih aspekata u ovom procesu transformacije jest i sve veća zaokupljenost humanista informacijskim tehnologijama u kojima vide moćan alat u smislu unaprjeđenja metodoloških postupaka, ali i kulturni objekt koji sada već jasno pokazuje pravce stvaranja novih teorijskih okvira.

Prema tome, utjecaj novih tehnologija izazovan je za mnoge, ali istodobno poziva na dijalog ne samo u kontekstu uspostavljenih disciplina, nego utječe i na ukidanje kvalitativnih/kvantitativnih, ali i teorijsko/praktičnih podjela. Disciplinu o kojoj ćemo u nastavku raspravljati u kontekstu termina humanističko računalstvo, humanistička informatika, digitalna humanistika, kulturna analitika³ nećemo definirati u kontekstu onih, u nacionalnim okvirima

³ I u kontekstu samoga terminološkoga određenja discipline postoje različita mišljenja, ali i nesuglasice. I premda se u raspravama o ovoj temi najčešće govori o računalnoj i digitalnoj humanistici, te u posljednje vrijeme i o kulturnoj analitici, moguća je, kako sugerira Melissa Terras (Terras 2013), upotreba i sljedećih termina: digitalni izvori za humanističke znanosti,

relevantnih znanstvenih područja i polja. Skloniji smo ovim prvim izdanjem otvoriti niz pitanja, ukazati na eventualne probleme s kojima se područje susreće, raspraviti o nužnosti implementiranja digitalnih alata u različita područja istraživanja, ukazati na važnost obrazovanja i cjeloživotnih edukacija koje osposobljavaju znanstvenike i istraživače u upotrebi tehnologija ovisno o njihovim potrebama, specifičnostima područja istraživanja i problema koje tijekom istraživačkoga procesa nastoje riješiti. Nadalje, smatramo kako spoj informacijsko-komunikacijskoga područja znanosti i humanističkih disciplina predstavlja jedno od mogućih rješenja u diskusiji situiranja digitalne humanistike u okvire znanstvenih područja i polja.

Kako se već iz iznijetoga dade naslutiti, a i detaljnije ćemo o tome u nastavku ovih uvodnih poglavlja, čitav je niz nejasnoća oko pokušaja definiranja digitalne humanistike, kao i neslaganja oko toga je li riječ o zasebnom znanstvenom području, samostalnoj disciplini ili poddisciplini neke već etablirane znanstvene discipline. Jednako tako, nismo niti posve sigurni je li riječ o pojmu o kojemu valja pisati i misliti u jednini ili množini, digitalna humanistika ili digitalne humanistike. Ne možemo sa sigurnošću tvrditi niti da će sam termin digitalna humanistika biti relevantan kroz dva ili tri desetljeća. Možda će pridjev „digitalno“ postati pleonastičan pa ćemo ga jednostavno morati izostaviti ili zamijeniti nekim prikladnijim. Pitanja bismo, a s obzirom na doista specifičnu temu mogli otvarati unedogled. Međutim, ono s čime se moramo složiti i posebno naglasiti na samom početku ove knjige i unatoč pa i

digitalni izvori u humanističkoj znanosti, književno i jezično računalstvo (str. 68).

neovisno o brojnim formalnim, pravnim, zakonskim nejasnoćama i zavrzlamama oko definiranja pojedinih područja, polja, disciplina – digitalna humanistika pretpostavlja istraživača otvorenoga eksperimentirati digitalnim alatima na nove načine.

Dodajmo još kako ćemo na tragu izlaganja Patrika Svenssona (2016) u knjizi *Big Digital Humanities. Imagining Meeting Place for the Humanities and the Digital*, pojam disciplina nastojati konzistentno koristiti kako bismo ukazali na još uvijek evidentnu nestabilnost digitalne humanistike u kontekstu utvrđenih znanstvenih područja i polja. Na taj ćemo način ipak sugerirati kako raspravljamo o oblasti koja još uvijek nije u ravnopravnom položaju s drugim znanstvenim disciplinama.

Humanističko računalstvo

Propitivanje, poticanje na razmišljanje, skepticizam, isticanje važnosti teorijsko-povijesnoga konteksta i usredotočenost na sadržaj, neka su od temeljnih obilježja znanstvenih istraživanja svojstvenih humanističkom području znanosti. Okupljanje oko većih i naglašeno interdisciplinarnih znanstvenih projekata, isticanje nužnosti primjene konkretnih metodoloških postupaka i poticanje objektivizacije istraživanja, ukazivanje na značaj primjene računalnih alata za analizu konkretnoga istraživačkoga problema, itd. – središnje su teme brojnih znanstvenih radova, eseja i rasprava kojima se od kraja Drugoga svjetskoga rata inicira razvoj nove discipline, tj. humanističkoga računalstva (HR).⁴ Izazovi ovih novih istraživanja temelje se na unapređenju i

⁴ Premda Nikolić (2016) ističe kako je u Hrvatskoj ustaljen naziv *društveno-humanistička informatika* pozivajući se na naziv Katedre za

nadopunjavanju tradicionalnih pristupa problemu, svojstvena im je usmjerenost prema nekim drugim zanimanjima i praksama koji uključuju korištenje softvera, analitičkih i statističkih alata, izradu baza podataka, kao i ostale modalitete koji podrazumijevaju rad u digitalnim medijima i s novim tehnologijama (Hayles 2012, str. 9). Takva istraživanja mogu, zasigurno jesu, ali i još uvijek predstavljaju izazov humanistima obrazovanim u kontekstu tradicije tiska i onima koji su veći dio karijere proveli u tradicionalnoj istraživačkoj atmosferi.

Godine 2009. godine u *The Digital Humanities Manifesto 2.0*, Schnapp i Presner upozorili su kako DH nije jedinstvena disciplina. Radi se o nizu konvergentnih praksi koje istražuju svijet u kojem tisak više nije ekskluzivni ili normativni medij posredstvom kojega se znanje producira i/ili diseminira, nego je inkorporiran u nove, multimedijske konfiguracije. Dakle, riječ je o disciplini koja podrazumijeva praktični moment; uključuje digitalne alate, tehnike i medije koji su promijenili načine nastanka i širenja znanja iz područja umjetnosti, ali i iz društveno-humanističkih znanosti. Značajne promjene koje zahvaćaju humanističke znanosti događaju se, kako ćemo detaljnije obrazložiti u nastavku, od četrdesetih godina 20. st., a nagli razvoj obilježava pojava World Wide Weba i interneta, kada se DH sve više nastoji formirati kao legitimna disciplina koja se institucionalizira u kontekstu studijskih

društveno-humanističke znanosti Filozofskoga fakulteta Sveučilišta u Zagrebu, mi ćemo u ovoj knjizi govoriti o humanističkom računalstvu prvenstveno iz razloga što držimo kako se digitalna humanistika nastavlja na, ali i izrasta iz humanističkoga računalstva. S obzirom da se u kontekstu digitalne humanistike ne rabi pojam „društveni“, toga ćemo se principa držati i kod prvo spomenutoga termina.

programa, istraživačkih centara, znanstvenih časopisa, knjiga i sve većeg broja istraživača (isto., str. 23). DH nije samo utjecala na promjene problema i metoda istraživanja, nego funkcionira i kao poziv na intervencije koje je potrebno napraviti u kurikulumima studijskih programa usmjerenih na poučavanje umjetničkih i društveno-humanističkih disciplina.

U literaturi koja se bavi pitanjima HR-a i DH-a, kao jedan od najčešće spominjanih problema ističe se problem definiranja discipline, a spomenuti nagli razvoj tehnologije otvorio je prostor brojnim raspravama, kontroverzama i tenzijama među istraživačima. Jedna od takvih kontroverza obilježila je kasne devedesete godine 20. st. tijekom kojih je usvojen termin *digitalna humanistika* i to na inicijativu Johanne Drucker, Johna Unswortha, Jeromea McGanna i nekolicina drugih znanstvenika s *Institute for Advanced Technology in the Humanities*, Sveučilišta u Virginiji (IATH) (Hayles 2012, str. 24). I premda je određen broj znanstvenika i dalje preferirao termin *humanističko računalstvo* koji je već prethodno bio u upotrebi, za primjerice Stephena Ramsaya i njegove kolege termin *digitalna humanistika* signalizirao je prelazak discipline gotovo nižega statusa koja je nerijetko funkcionirala kao sinonim za kakvu podršku korisnicima, u istinski intelektualni pothvat sa svojom vlastitom profesionalnom praksom, ozbiljnim standardima i uzbudljivim teorijskim objašnjenjima (isto). Među brojnim autorima ističe se Kirschenbaum (2012) koji je pratio razvoj termina te se složio s mišlju kako je *digitalna humanistika* pojam superioran *humanističkom računalstvu* iz razloga što uključuje *oblik humanizma* (str. 25).

Velikom broju rasprava iz područja HR-a i DH-a svojstvene

su upravo poteškoće oko definiranja discipline pa nerijetko s ciljem pobližega određenja brojni autori polaze od povijesti njihova razvoja. Sličnim smo putem i mi krenuli u ovom prvom, povijesno-teorijski utemeljenom dijelu knjige smatrajući kako ćemo povijesnim presjekom i uopće opisom ozračja unutar kojega su nastajale, funkcionirale i dalje se razvijaju ove discipline pripomoći i u njihovim pobližem određenju. Dakako, dolje iznijeti povijesni presjek razvoja HR-a referira se na neke od najznačajnijih projekata, publikacija i događaja koji su obilježili razdoblje od završetka Drugoga svjetskoga rata do devedesetih godina 20. st., te ga nikako ga ne treba shvatiti cjelokupnim prikazom navedenog razdoblja.

Istraživačko ozračje u području humanističkoga računalstva

Usmjeravanje humanističkih istraživanja prema informacijsko-komunikacijskim tehnologijama ne treba isključivo vezivati uz pojavu prvih računala za osobnu uporabu. Brojne promjene pratile su zapravo opću klimu koja je u to doba zahvatila književnu kritiku, osobito onu svojstvenu prvoj polovici 20. st. tijekom koje sve više jača svijest o značaju socijalne dimenzije koju je bilo potrebno inkorporirati u područje. Vjerojatno zbog općega poslijeratnoga društveno-kulturnoga ozračja, razvoju teorije književnosti značajno su pridonijeli i znanstvenici iz društvenoga područja i filozofi, poput primjerice Jacquesa Lacana, Jacquesa Derridaa, Michela Foucaulta, Rolanda Barthesa, Claudea Lévi Straussa, itd., koji su i sami težili nadopuni vlastitih istraživanja objektivnim metodama. S obzirom da posjeduju komponentu mjerljivosti, računalno utemeljena

humanistička istraživanja jednim dijelom izrastaju upravo iz te tradicije, ali se na tu istu tradiciju i nastavljaju (Raben 1991, str. 342).

Zanimljivo je, nadalje, istaknuti kako Roberto Busa u razdoblju od 1949. do devedesetih godina 20. st. razlikuje tri perspektive humanističkoga računalstva. Prva, tzv. „tehnološka minijaturizacija“ usredotočena je na tehnologije koje su se tijekom šezdesetogodišnjega razdoblja koristile u računalno humanističkim istraživanjima (tehnologija bušenih kartica, magnetskih kartica i CD ROM-ova). Druga perspektiva, „tekstualna informatika“ grana se u tri smjera. Prvi smjer je dokumentarni ili dokumentaristički, a uključuje banke podataka, internet i World Wide Web; drugi je urednički, a svojstvena mu je pojava CD-ova i njegovih nasljednika uključujući multimedijske i druge oblike reprodukcije knjige s audio-vizualnim dodatcima. Oba smjera na različite načine osiguravaju množenje, distribuciju, brzinu i praćenje informacija i teksta. Oba su prepoznatljiva po svom nastojanju da elektroničkim sustavom podrške prenesu i predstave, riječi i interpunkciju. Treći smjer, zapravo je treća perspektiva koju naziva „hermeneutičkom“ ili interpretativnom, a podrazumijeva onu informatiku koja je usko povezana s lingvističkom analizom, te je prvotno nastala s projektom *Indeks Thomisticus* 1949. godine (Busa 2008, str. 12).⁵

Među prvim autorima koji su promišljali društvenu ulogu računalnih tehnologija ističe se Warren Weaver. Inspiriran

⁵ Prema Busi (2008), ta se perspektiva najbolje opisuje na sljedeći način. U elektroničkom *Indexu Thomisticusu* svaka od 11 milijuna riječi sadržana je u zapisu od 152 bajta. Oko 22 su rezervirana za riječi, a 130 sadrži 300 izmjeničnih „unutarnjih hipertekstova“, koji specificiraju vrijednosti unutar razine morfologije (str. 12).

predratnim računalnim projektima i razvojem tehnologija kojemu je svjedočio tijekom Drugoga svjetskog rata, počeo je istraživati mogućnosti kojima tehnologija može pridonijeti u širem, društvenom smislu. Upravo u tom ranom poslijeratnom razdoblju tijekom kojega dolazi do širenja računalstva izvan vojnih okvira i valja tražiti začetke humanističkoga računalstva. Naime, ratna računalna praksa balistike i kriptanalize uvjerila ga je kako se računala mogu koristiti i u razdobljima mira, osobito u kontekstu akademskoga ozračja, te posebice u području znanosti i humanistike, odnosno matematike i strojnog prevođenja (Weaver 1970, citirano u Vanhoutte 2013, str. 122).

Strojno prevođenje podrazumijeva upotrebu računala u svrhu prijevoda jednoga prirodnoga jezika u drugi, a jedan od temeljnih dokumenata koji je inicirao istraživačke projekte upravo u području strojnoga prevođenja jest *Weaver Memorandum* objavljen 15. srpnja 1949. godine. *Memorandum* je ubrzo počeo kružiti među dvadesetak, tridesetak studenata lingvistike, logike i matematike, te među više od 200 istraživača različitih disciplina. Među prvim istraživačkim temama spominju se homonimija i sinonimija, semantička funkcija sintakse i problem redosljeda riječi u različitim jezicima. Godine 1952. održana je prva međunarodna konferencija o strojnom prevođenju na MIT-u, popraćena sastankom u Londonu kasnije te iste godine i to u vrijeme trajanja međunarodnoga simpozija lingvista, *International Linguistic Congress*. Godinu poslije, strojno prevođenje pojavljuje se prvi puta u znanstvenoj publikaciji pod naslovom *Automatic Digital Calculators* autora Andrewa i Kathleen Booth. Nadalje, 1954. godine na Sveučilištu Harvard obranjena je prva doktorska

disertacija (Anthony Oettinger), te je počeo izlaziti časopis pod nazivom *Mechanical Translation*.

Dakle, prva računalno potpomognuta istraživanja koja su obilježila razdoblje od kraja četrdesetih do početka sedamdesetih godina 20. st. uključuju generaciju istraživača usmjerenih izradi registara riječi u svrhu otklanjanja poteškoća oko datiranja djela poznatih autora. Pojavljuju se jednako tako i istraživanja kojima se nastojalo dokazati ili osporiti autorstvo; definirati stil nekoga djela ili autora; sastavljali su se indeksi i rječnici koju su uključivali popise riječi koje su koristili pojedini pisci ili su pak predstavljali cjelokupni vokabular nekoga djela ili skupine djela. Definicija stila uglavnom se temeljila na numeričkima podacima, npr. broj riječi u rečenici, dok se autorstvo uglavnom utvrđivalo zahvaljujući nekim minornim i neprimjetnim verbalnim elementima pa se tijekom ove najranije uporabe računalo uglavnom svodilo na gotovo ekskluzivnu funkciju brojača (Hockey 2012, str. 85).⁶ Smatra se da je prva uporaba računala u istraživanju spornoga autorstva provedena na Junijevim pismima Alvara Ellegarda iz 1962. godine. Iako se računalo nije koristilo za prebrojavanje riječi, korišteni strojni izračuni pomogli su Ellegardu u oblikovanju cjelovite slike o vokabularu. Jedno od prvih utjecajnih računalnih istraživanja u području utvrđivanja autorstva jest ono spočetka šezdesetih godina 20. st. Riječ je o istraživanju *Federalističkih spisa* koje su proveli Mosteller i Wallace, s ciljem utvrđivanja autorstva u dvanaest

⁶ Korištenje kvantitativnih pristupa u proučavanju stila i autorstva prethodilo je računalstvu pa je tako primjerice Augustus de Morgan u pismu napisanom 1851. godine predložio kvantitativnu studiju vokabulara kao alat za istraživanje autorstva Pavlovih poslanica (Hockey 2012, str. 85).

spornih radova. Studija je predstavljala izvrstan primjer usporedne analize, korištene su statističke metode, a autori su pokazali kako je Madison vrlo vjerojatno bio autor spornih radova. O značaju ove studije govori i podatak kako je ona kasnije korištena kao test za nove metode u utvrđivanju autorstva (Holmes i Forsyth 1999 citirano u Hockey 2012).

Još je jedan zanimljiv rani projekt u području HR-a, onaj Josephine Miles koji je uključivao brojanje ključnih riječi (npr. *ljubav* ili *čast*) u pjesništvu različitih razdoblja.⁷ Potom su Miles L. Hanley i Harold Whitehall bili zaokupljeni oralnim karakteristikama jezika te su nastojali rekonstruirati zvukove engleskoga jezika i različite načine izgovora tijekom prošlosti. Izdvojili su sve neuobičajene rime u engleskom pjesništvu u razdoblju od 15. do 19. st. Riječ je o, iz današnje perspektive promatrano, naivnom i idealističkom pothvatu koji bez obzira na navedeno pokazuje tendenciju da se humanističke studije orijentiraju prema onoj istoj (ili barem sličnoj) vrsti širokog i činjenično utemeljenoga pristupa svojstvenoga društvenim i prirodnim znanostima. Ono što povezuje ove i slične rane projekte jest pokušaj sakupljanja što većega broja podataka koji mogu poduprijeti donošenje objektivnih zaključaka,

⁷ U tim ranim godinama razvoja discipline velika se pozornost posvećivala ograničenjima tehnologije. Podaci koji su se analizirali bili su ili tekstovi (slovni znakovi) ili brojevi. Unosili su se ručno ili na bušenim karticama, pri čemu je svaka kartica sadržavala do osamdeset znakova ili jedan red teksta (samo velika slova). Predstavljanje skupova znakova ubrzo je prepoznato kao značajan problem, a koji se počeo rješavati tek pojavom *Unicodea*. Osmišljene su različite metode za predstavljanje velikih i malih slova na bušenim karticama, najčešće umetanjem zvjezdice ili sličnog znaka ispred velikog slova. S naglascima i drugim nestandardnim znakovima trebalo je postupati na sličan način, a nelatinična pisma u potpunosti su bila predstavljena transliteracijom (Hockey 2012, str. 82).

a tim se nastojanjem povodilo i pri izradi višetomnog *Oxford English Dictionary* kojim se htjelo pratiti svaku riječ u modernom engleskom jeziku i to do njezina najranije zabilježenoga oblika.⁸

U razdoblju od 1955. do 1966. godine, disciplina se organizirala uglavnom oko s jedne strane rada na rječnicima, leksikografskim i semantičkim problema, a s druge su se strane istraživali sintaktički problemi. Prva je grupa istraživanja, koja se koncentrirala na prostor Velike Britanije prigrllila empirijski pristup, a druga, koju je karakterizirao uglavnom teorijski pristup karakteristična je za prostor SAD-a. Međutim, 1966. godinu obilježio je jedan događaj koji je bitno utjecao na daljnji razvoj HR-a. Naime, te je godine SAD prestao financirati istraživanja u području strojnoga prevođenja kritizirajući troškove, svrhu i uopće potrebu za strojnim prevođenjem, ističući pritom kako je engleski jezik ionako dominantni jezik znanosti i kako bi isplativije bilo podučavati korisnike ruskih članaka ruskom jeziku, nego im pružiti „prevoditeljski servis“. Ova je, dakle, odluka kako za lingviste općenito, tako i za istraživače u području računalne lingvistike i HR-a odredila budućnost istraživačkih projekata. U tom je kontekstu Vicotr Yngve istaknuo kako budućnost lingvistike nije u filozofiji iz koje, doduše, izrasta, nego u standardnim znanostima prema kojima se tada počela uvjerljivo kretati. Navedeno znači da

⁸ U izradu je bilo uključeno tisuće volontera koji su čitali zadane tekstove i na cedulje ispisivali sve neobične riječi ili riječi koje su bile upotrebljavane na neuobičajeni način. Sve te primjere desetljećima je analizirao iznimno mali tim pod vodstvom Jamesa Murraya s Oxforda te su na koncu proizveli epohalni rječnik. Dakako, u izuzeću računala ovo je iznimno težak i dugotrajan posao koji zahtjeva angažiranost velikoga broja ljudi. Svaki moderni rječnik, pa tako i nove edicije OED-a podrazumijevaju korištenje računala. Drugo izdanje OED-a dizajnirano je kao baza podataka (Raben 1991, str. 342-343).

su istraživači u području morali prihvatiti kako središte njihovih istraživanja postaje čovjek koji govori, razumije i komunicira na drugačiji način i u kontekstu drugačijih aspekata stvarnoga svijeta (Vanhouette 2013, str. 125). Na taj se način inicirao svojevrsni razlaz između strojnoga prevođenja i leksičke tekstualne analize.

Izgleda da se upravo Roberto Busa složio sa stavovima koje je iznio Yngve, a koji je je uočio ne toliko neadekvatnost računala u odnosu na ljudski jezik, koliko čovjekovo nedostatan razumijevanje ljudskoga jezika. Bilo kako bilo, činjenica jest da je strojno prevođenje bilo iznimno snažno uključeno u elektroničku obradu humanističkih podataka. Rani radovi na ovu temu spominju esencijalnu upotrebu registra riječi, frekvencija i lematizacija koji su tipični produkti leksičke tekstualne analize (*Lexical Text Analysis – LTA*) (isto., str. 126). U svojoj temeljnoj formi tiskani registri riječi sastoje se, neovisno o tome jesu li razvijeni na tradicionalni način ili uz pomoć računalnih alata, od tri komponente: naslovne riječi, dovoljno konteksta kako bi se pokazala njezina funkcija, i citata na izvornik. Iz ekonomičnih razloga, ali i zbog troškova tiska, riječi poput prijedloga, zamjenica ili članova gotovo su se uvijek izostavljale. Signifikantne riječi, tj. riječi koje se nisu izostavljale predstavljale su veliku većinu riječi neke pjesme ili drame pa su računalni alati u takvim istraživanjima bili od nezamjenjive pomoći. Programi usmjereni stilističkoj analizi teksta i stilometriji razvijeni su ranih šezdesetih godina prošloga stoljeća.

Svakako, jedan od najznačajnijih projekata usmjeren upotrebi LTA, bio je *Index Thomisticus* Roberta Buse, koji je obuhvaćao lematiziranu podudarnost u kojoj su riječi navedene pod

svojim rječničkim naslovima, a ne pod njihovim jednostavnim oblicima. Riječ je o Businoj doktorskoj disertaciji koju je izradio u izuzeću računalne tehnologije. Međutim, 1951. godine susreo s inženjerima IBM-a u New Yorku s ciljem iznalaženja rješenja za automatski prijevod podudarnosti u poeziji Tome Akvinskoga, a što je bio prvi primjer indeksa riječi tiskanoga uz pomoć tehnologije bušenih kartica (usp. isto). Inovacija ovoga projekta temelji se na Businu shvaćanju prema kojem se komercijalni računalni strojevi i te kako mogu koristiti u svrhu humanističkih istraživanja i kako ta upotreba može dati iznimne rezultate. I dok je Busa koristio tehnologiju bušenih kartica i to u uskoj suradnji s IBM-om, John W. Ellison je 1957. godine završio svoj *Computerized Concordance to Revised Standard Version of the Bible*, uz računalnu pomoć, tj. tehnologijom magnetske trake i UNIVAC I glavnoga računala.

Manje-više slični projekti koji su se razvijali u narednim godinama pokazali su ipak nešto više kreativnosti u korištenju računalnih mogućnosti.⁹ Prvotno su se razvili alati koji su se koristili za analizu poezije i dramskoga pjesništva, a tek potom oni za narativne forme i dramske tekstove. Tako je primjerice Marvin Spevack izradio registar riječi cjelokupnoga Shakespeareova dramskoga pjesništva, a koji je objavljen kao sažeti pregled ukupnoga vokabulara, ali i kao odvojene analize svakoga pojedinoga dramskoga djela. Nadalje, Linda Misesk izradila je registar Miltonova *Izgnanoga kralja* koji je uključivao netipične informacije, a s ciljem prikazivanja povezanosti književnoga

⁹ Većina skupova podataka velikih razmjera bila je pohranjena na magnetskoj vrpici koja se mogla obrađivati samo serijski. Bilo je potrebno oko četiri minute da se vrpca pune veličine premota s jednoga kraja na drugi, pa je softver osmišljen kako bi minimizirao količinu pomicanja trake.

junaka s određenom situacijom u djelu. Tehnike koje su koristili ovi istraživači omogućile su precizniji uvid u razvoj karaktera u književnom djelu, ali i načine na koje su pojedini književnici razvijali i koristili vlastiti leksik. Registri riječi organizirali su se na način da su se riječi grupirale sukladno semantičkim, a ne abecednim karakteristikama.

Sljedeći važan trenutak u razvoju humanističkoga računalstva vezan je uz 1987. godinu kada se grupa od trideset i dvoje istraživača iz područja humanistike okupila na dvodnevnom sastanku kojega je organizirao *Assocation of Computers and the Humanities* (ACH), i kojega su vodili Nancy Ide i Michael Sperberg-McQueen, a s ciljem utvrđivanja načina i metoda uvođenja strojnoga čitanja teksta za humaniste. Zaključci su formulirani kao skup metodoloških principa poznatih pod nazivom *Poughkeepsie Principles*. Riječ je o načinu pripreme teksta za kodiranje u kontekstu književnih, lingvističkih i povijesnih istraživanja. U implementaciji ovih principa ACH-u su se pridružili ALLC i *Association for Computational Linguistic* (ACL), koji su zajedno utemeljili *Text Encoding Initiative* (TEI), a čija je zadaća bila razviti smjernice za kodiranje teksta. TEI je vrlo skoro prihvatio *Standard Generalized Markup Language* (SGML) i ISO standard objavljen 1986. godine kao prihvatljiv format za kodiranje elektroničkih tekstova.¹⁰

¹⁰ Prvi javni prijedlog za *TEI Vodič* objavljen je u srpnju 1990. godine pod naslovom *Guidelines for the Encoding and Interchange of Machine Readable Texts*, s TEI brojem *TEI P1 – za Prijedlog 1*. Godina 1992. i 1993. objavljen je *TEI P2*, a 1999. razvoj TEI-a završen je konačno objavljenim vodičem *TEI P3 Guidelines for Electronic Text Encoding and Interchange*, definirajući 439 elemenata. Ovim radom osiguran je okvir za kodiranje tekstova na bilo kojem prirodnom jeziku, bilo koje starosti i bilo kojega žanra. Godine 2002. objavljen je vodič za *TEI P4*, a 2003. TEI konzorcij je objavio novu, *P5*

Od sredine osamdesetih do ranih devedesetih godina 20. st. evidentni su značajni pomaci, a razloge dijelom valja, kako upozorava Hoceky (Hockey 2004), tražiti u razvoju novih tehnologija, razvoju osobnih računala i elektroničke pošte. Do kraja osamdesetih godina 20. st. postojala su tri programa za analizu teksta utemeljena na DOS-u: *Word Cruncher*, *TACT* i *MicroOCP*. Sva tri imala su jako dobro razvijene funkcije, privukli su brojne korisnike oskudnoga tehničkoga znanja koji su nerijetko smatrali kako su funkcije u kontekstu programa za obradu riječi sve ono što računala stvarno mogu. Nadalje, nije naodmet istaknuti kako je upravo Apple Macintosh bio osobito atraktivan za humaniste, i to iz dva razloga. Prvo, za osobna je računala razvijeno grafičko korisničko sučelje prije Windowsa, što znači da je bilo učinkovitije u prikazivanju nestandardnih karaktera i znakova. U najmanju ruku, moglo je prikazati grčka i ćiriljska slova, kao i gotovo svaku drugu abecedu i to uz mogućnost vrlo jednostavne manipulacije teksta sastavljenoga od simbola i znakova. I drugo, Macintosh je dolazio s programom koji je omogućavao izgradnju jednostavnih hipertekstova na jednostavan način.

S vremenom je, kako smo istaknuli, počeo rasti i interes za kodiranje teksta, a što je podrazumijevalo postojanje izvora u obliku pogodnom za strojno čitanje. Takvih je izvora početka bilo malo, no pojava CD ROM-a omogućila je rad na, uz primjenu odgovarajućega softvera, stotinu književnih djela i rječnika. Okupljanje ovih različitih izvora informacija na novom mediju s vremenom je ukazalo na potrebu stvaranja baza podataka, a kao

verziju koja sadrži potpuni XML izraz, s uputama za nove modele i obnovu postojećih (Vanhouette 2013, str. 134).

jedan od značajnijih ranijih leksikografskih projekata kojega je vodio Frederic G. Casidy sa Sveučilišta Wisconsin izdvaja se *Dictionary of American Regional English*. Među zanimljivim računalnim aplikacijama koje su podržavale ovaj višetomni rad posebno se ističe ona s mogućnošću prikaza svake države u veličini proporcionalnoj broju stanovnika. Kako god se unosila neka od leksičkih jedinica, leksikografima je bila slikovito prikazana njezina rasprostranjenost u različitim dijelovima zemlje. Projekt se dalje nastavio razvijati na Sveučilištu Freiburg pa su u sljedećoj fazi izrađene računalno generirane karte koje su prikazivale dijalektalne varijacije i to u jednom od posljednjih u seriji lingvističkih atlasa nastalih na prijelazu 20. stoljeća, *Dialect Atlas of South-West Germany* (Raben 1991, str. 346).

Razvojem HR-a, porastom broja projekata i različitih istraživanja pojavila se bojazan od dupliciranja napora pa su značajne promjene zahvatile i područje arhiviranja i održavanja teksta. Tako je 1976. godine razvijen *Oxford Text Archive* (OTA) kojemu je svrha zapravo bila čuvanje teksta. OTA je, dakle, trebao održavati elektroničke tekstove dostupne svima koji su ih željeli koristiti u akademske svrhe. I bez obzira što ih početka nitko nije tako zvao, bili su to počeci digitalne knjižnice (Hockey 2004). OTA je nudio uslugu održavanja svega što je pohranjeno tijekom dužega razdoblja, no postojale su jednako tako i grupe znanstvenika koji su nastojale stvoriti vlastite arhive tekstova koje bi im koristile u provedbi istraživanja. Takav značajniji arhiv bio je *Thesaurus Linguae Graecae* (TLG) koji je započeo na kalifornijskom sveučilištu Irvine, i kojim je godinama upravljao Theodore Brunner. Brunner je prikupio milijune dolara kako bi podržao stvaranje

banke podataka starogrčkih tekstova, pokrivajući sve autore od Homera do onih iz oko 600. godine, dakle oko 700 milijuna riječi. Komplementarnu zbirku klasičnoga latinskog jezika kasnije je proizveo Packardov institut za humanističke znanosti, i zajedno s TLG-om ponudio je istraživačima klasičnih studija istraživački resurs koji je godinama bio bez premca u drugim disciplinama. Samo su znanstvenici staroengleskoga jezika, a dovršetkom korpusa za Rječnik staroengleskoga, imali pristup sličnom sveobuhvatnom, ali ipak manjem korpusu (isto).

Nadalje, jedna od zanimljivijih baza podataka verbalnih zapisa izvedena je iz župnih registara rođenih, vjenčanih i umrlih i to diljem Europe, a ovi su dokumenti nerijetko predstavljali jedine povijesne zapise prije 19. st. Pažljivo povezujući unose, povjesničari su zabilježili obrasce brakova i prijenosa zemlje, izveli su stope nataliteta i smrtnosti, povezivali su promjene u običajima s većim povijesnim događajima, npr. ratovima, kugama, itd., te su na taj način i rekonstruirali povijest generacija obitelji. Jednako je tako značajna i baza podataka koju je razvio Ben R. Schneider sa Sveučilišta Lawrence koristeći već objavljene dnevne zapise o predstavama koje su četiri londonska kazališta izvodila u razdoblju od 1660. do 1800. godine. Schneider je ovim svojim radom nastojao predstaviti iznimno važne informacije kojima se nastojalo teatru osigurati mjesto javnoga medija i koji je svojedobno imao ulogu jednaku onoj koju je kasnije preuzela televizija. Uz postojanje ovih verbalnih zapisa, humanisti su jednako tako oduvijek bili okupirani i glazbenim i vizualnim zapisima. Tako je jedan od impresivnijih projekata povezanih s vizualnim materijalima kompilacija od 108000 fotografija i ostalih materijala koji se odnose na prvog

kineskoga cara i ratnika, a koje je sakupila i organizirala Ching-chih Chen sa Simmons Collegea. Nepokretne i filmske slike, zvučni zapisi glazbe i intervjui (na engleskom i kineskom jeziku) bili su inkorporirani na video disk pa ih se moglo pretraživati na različite načine, a bilo je omogućeno i zumiranje. Chen je potom koristeći Hyper-card Apple računalo i C-Quest Image Concepts, razvila vlastitu originalnu bazu interaktivnih izvora namijenjenu istraživanju i poučavanju. Tako je primjerice bilo moguće odabrati fotografiju i vratiti izvornu boju ratnicima, onakvu kakvom su i slikani u trenutku smrti prije više od 2200 godina (Raben 1991, str. 348).

Sljedeći važan trenutak u razvoju HR jesu rane devedesete godine 20. st., koje je obilježio dolazak interneta i World Wide Weba i koji su postali vitalnim dijelom svakodnevne akademske aktivnosti. Uz internet je odrasla i generacija studenata koja ga je prirodno smatrala prvim izvorom svake informacije. U početku su neki, tada već dugogodišnji praktičari u području HR-a nevoljko gledali na mogući utjecaj weba, posebice oni uključeni u TEI koji su smatrali da je *HyperText Markup Language* (HTML) slabi sustav označavanja koji je samo produžio sve probleme s programima za obradu teksta i označavanja temeljenim na izgledu. Na web se gledalo sa znatiželjom, bilo je to sredstvo za pronalaženje informacija, ali nije se shvaćao ozbiljnim alatom za humanistička istraživanja. No, početkom i sredinom devedesetih godina 20. st. najavljen je veći broj projekata i to osobito u području elektroničkih znanstvenih izdanja čime se proširila ideja o važnosti i mogućnostima koje tehnologija može ponuditi humanistima. Tako su se počeli razvijati i prvi izdavački projekti koje su isprva pokrenule akademske institucije,

ali i knjižnice su ubrzo počele razmišljati o postavljanju sadržaja svojih zbirki na internet. Nekoliko institucija u SAD-u postavilo je tako zbirke elektroničkih tekstova ili digitaliziranih knjižnica najčešće koristeći tražilicu *OpenText SGM*, dok su drugi projekti za isporuku svojih materijala koristili *DynaText SGML* elektronički sustav knjiga. Ponudilo je to strukturirano pretraživanje, doduše s ne osobito intuitivnim sučeljem pa je inovativnu ideju za elektroničku publikaciju razvio projekt Orlando, koji je stvarao Povijest britanskoga ženskog pisma na Sveučilištima Alberta i Guelph. Riječ je o arhivi dokumenata sastavljenoj od kratkih biografija autora, razdoblja kojem pripadaju razvijenoj kao web-utemeljen sustav za upravljanje dokumentima koji koristi neke od SGML¹¹ oznaka u administrativne svrhe (Hockey 2004, str. 23).

Sve rasprostranjeniji pristup elektroničkim izvorima koje je potaknuo internet proširio je teorijske rasprave pa su tako sami elektronički izvori postali objekti proučavanja te su postali središnje mjesto za analizu kod nove skupine znanstvenika, od kojih su neki imali prilično slabo tehničko znanje. Hipertekst je primjerice posebno privukao veliki broj teoretičara, što je pridonijelo proširivanju raspona interesa i rasprava o HR-u. No, od samih početaka razvoja ove discipline, a svojstveno je to i suvremenim raspravama, razvidne su dvije struje znanstvenika od kojih je jedna usmjerena teorijskom obrazlaganju bez dubljega zalaženja u problematiku tehnologija, a druga se mahom koncent-

¹¹ SGML (Standard Generalized Markup Language), uglavnom na aplikacijama temeljenim na TEI-u. U ranim danima weba, tehnologija za isporuku tekstova kodiranih SGML-om bila je nezgrapna i na mnogo je načina predstavljala manje zadovoljavajuće korisničko sučelje od onoga što se može isporučiti s neobrađenim HMTL-om (Hockey 2004, str. 22).

rirala upravo na praktični rad.

Iz navedenoga je sasvim jasno kako su se razvojem tehnologije unaprjeđivali i humanistički projekti, ali i računalni alati za istraživanje teksta, zvuka i slike. Već je i u samim počecima razvoja HR-a bilo očito kako su tehnologije neizostavna pomoć u provedbi humanističkih istraživanja. One su s jedne strane omogućile stvaranje materijala kao izvora informacija za poučavanje i istraživanje, a s druge su potaknule izradu alata za istraživanje i daljnju razradu tih istih informacija.

Institucionalizacija humanističkoga računalstva

Povijest strojnoga prevođenja i leksičke tekstualne analize usko su povezani s razvojem tehnologije i računala, programskih jezika i softvera, ali i ekonomskim prednostima koje su ovi proizvodi nudili. U godinama nakon Drugoga svjetskog rata tradicionalna proizvodnja analogne opreme zamijenjena je digitalnom računalnom opremom koja je, pak, snažno utjecala na stvaranje novih tržišta. U tome i jest razlog zašto su se neki od lidera toga doba, poput primjerice Remington Reda i IBM-a, ekipirali s humanističkim istraživačima i financirali projekte i konferencije na kojima su se istraživale nove mogućnosti računalstva. Jedna od prvih konferencija jest ona održana na Sveučilištu Yale u siječnju 1965. godine, pod nazivom *Computers for the Humanities?*, a istoimeni zbornik radova drži se jednim od najranijih izdanja koje okuplja istraživanja ove rane uporabe

računala u humanistici.¹² Dvije godine kasnije, odabrani radovi koji se uglavnom usredotočuju na propitivanje uporabe računala u antropologiji, arheologiji, povijesti, političkim znanostima, jeziku, književnosti i muzikologiji – objavljeni su pod sponzorstvom IBM-a, u publikaciji naslovljenoj *Computers in Humanistic Research. Readings and Perspectives* (Vanhoutte 2013, str. 129).

Britanski centar *Literary and Linguistic Computing Centre* (LLCC) sa Sveučilišta Cambridge kojega je kao prvi ravnatelj utemeljio Roy Wisbey 1964. godine, također je pokrenuo međunarodnu konferenciju o upotrebi računala u istraživanjima u području lingvistike i književnosti. Godine 1970. ova je konferencija okupila istraživače iz Velike Britanije, Australije, Kanade, SAD-a, kontinentalne Europe. Nagli razvoj upotrebe računala u filološkim disciplinama očituje se i u nazivu još jednoga centra pokrenutoga 1973. godine, *Literary and Linguistic Computing* (ALLC) koji je izdavao periodiku *ALLC Bulletin*, od 1973. do 1985. godine, odnosno *ALL Journal* od 1980. do 1985. godine. Obje publikacije zamijenio je 1986. godine časopis *Literary and Linguistic Computing* (LLC) koji je 2005. godine promijenio naziv u *LLC: The Journal of Digital Scholarship in the Humanities* (isto).

ALLC je započeo s organizacijom serije konferencija koje su se održavale svake dvije godine, a od 1973. godine nadalje alterirale su s američkim konferencijom *International Conference on Computer in the Humanities* (ICCH). Profesionalna organizacija

¹² Zbornik je sadržavao radove koji istražuju i propituju povijest uporabe računala u znanosti; potom radove o računalima i riječima, jeziku i književnosti; računalima i povijesti; računalima i umjetnosti; ali i rasprave o mogućim budućim projektima.

pokrenuta u SAD-u 1978. godine, nosila je naziv *Association for Computers and the Humanities* (ACH), a dvanaest godina prije Joseph Raben pokrenuo je časopis *Computers and the Humanities* (*CHum*) koji je izlazio od 1966. do 2004. godine. Zanimljivo je u ovom kontekstu istaknuti da su za razliku od istraživanja koja su se provodila u Europi i koja su uglavnom bila orijentirana na književnost i lingvistiku, te studije jezika u književnosti, istraživanja koja su predstavljana na konferencijama i časopisima u SAD-u bila mahom koncentrirana na računalno utemeljene studije jezika u književnoj, ali i neknjiževnoj formi.

Jedan od prvih časopisa koji je odigrao značajnu ulogu u formiranju ove discipline pokrenut je 1966. godine pod nazivom *Computers and the Humanities*. Prvi brojevi u kojima su se našli članci poput *PL7I: A Programming Language for Humanities Research, Art, Art History, and the Computer, Musicology and the Computer in New Orleans*, nisu u središte istraživanja postavljali tekst. Značajniji pomak prema tekstu vidljiv je u brojevima izdanima u razdoblju od 1966. do 1977. godine (Svensson 2013, str. 47). Nadalje, 1973. godine počinje s djelovanjem *Association of Literary and Linguistic Computing* (ALLC), a 1986. objavljen je prvi broj časopisa *Literary and Linguistic Computing* u izdanju Oxford University Pressa. Potom je ranih devedesetih godina 20. stoljeća osnovan *Association of Computers and the Humanities* (ACH). Takozvani međunarodni elektronički seminar *The Humanist* počeo je izlaziti 1986. godine, a poznata godišnja konferencija koja okuplja istraživače koji se bave problematikom digitalne humanistike u organizaciji ALLC-a izlazi od 1970., a u suorganizaciji s ACH-om od 1989. godine. Valja, nadalje, spomenuti i godišnju konferenciju u području mahom

orijentiranu na britanski istraživački prostor pod nazivom *Digital Resources in the Humanities*, koja je prvi puta održana 1996. godine (Terras 2013, str. 75).

Međutim, prva monografija o računalima u humanistici došla je iz računalne industrije 1971. godine kada je IBM objavio seriju priručnika o upotrebi računala u humanistici: *Introduction to Computers in the Humanities*, *Literary Data Processing* i *Computer sin Anthropolgy and Archeology*. Točno deset godina nakon ovih prvih monografskih izdanja izlaze dva udžbenika, jedan autorice Susan Hockey *A Guide to Computer Applications in the Humanities* i autora Roberta Oakmana *Computer Methods for Literary Research*, koji su iz akademskoga očišta osigurali konzistentni pregled uporabe računala u humanističkim istraživanjima.

Jedno od prvih spominjanja termina *humanističko računalstvo* evidentirano je u članku drugoga broja časopisa *CHum*, a odnosilo se na upotrebu PL/I kao programskoga jezika za humanistička istraživanja 1966. godine. Godine 1968. Aldo Duro objavio je istraživanje pod naslovom *Humanities Computing Activities in Italy*, u kojem ukazuje kako je termin već vrlo dobro poznat, ali još uvijek nije dominantan u zajednici. Dakle, šezdesete godine 20. st. karakterizira uvođenje u terminologiju, tijekom sedamdesetih godina počeo se sve više označavati disciplinu, a u osamdesetima je bio već široko rasprostranjen. Od sredine osamdesetih godina naovamo, termin *humanističko računalstvo* pojavljuje se u obrazovnim programima u Sjevernoj Americi, te u računalnim centrima (Sveučilište Washington i Sveučilište McMaster) i ustanovama (Sveučilištima Arizona State i Duke, i na UCLA-u) (Vanhoutte, 2013 str. 131-132).

U hrvatskoj znanosti začetke humanističkoga računalstva valja vezati uz ime Bulcsúa Lászlóa, osnivača Katedre za algebarsku i računalnu lingvistiku i jedne od središnjih figura Zagrebačkoga lingvističkog kruga. Zahvaljujući spoju obrade informacija i uporabe računala u opisu prirodnoga jezika usmjerio je Odsjek za opću lingvistiku Filozofskoga fakulteta u Zagrebu novim, inovativnim strujama te je upravo iz toga razloga osobiti značaj u njegovoj nastavi imalo algebarsko i računalno jezikoslovlje kojega je i uveo u hrvatsko jezikoslovlje. O važnosti algebarskoga i računalnoga jezikoslovlja pisao je i u radovima, *Strojno prevođenje i statistika u jeziku* u koautorstvu sa S. Petrovićem i *Broj u jeziku* iz 1959., te *Strojno prevođenje i naši neposredni zadaci* u koautorstvu s B. Finkom iz 1962. godine. Jednako tako, László je jedan od utemeljitelja informacijskih znanosti, te je i pokretač dvogodišnjega studija društveno-humanističke informatike (1976.), te četverogodišnjega studija informacijskih znanosti (1986.) na Odsjeku za informacijske i komunikacijske znanosti na Filozofskom fakultetu u Zagrebu (Tadić, 2016).

Humanističko računalstvo u kontekstu visokoga obrazovanja

Još je 1987. godine u časopisu *Computers and the Humanities* objavljen članak pod naslovom *Computers and the Humanities Courses: Philosophical Bases and Approaches* u kojem su iznijeti stavovi o važnosti implementiranja elemenata informatike i računalstva u studije humanistike. Zaključci su doneseni nakon radionice održane na Vassar College-u na kojoj su i sudionici i publika

iznijeli dvije važne teze. Prva se odnosila na činjenicu kako su studenti u humanističkom području znanosti već tada pokazivali sve značajniji interes za znanjima u području računalstva, a druga se teza odnosila na neophodnost osiguravanja specijalizirane obuke u području. Prvi zahtjev ukazuje na blisku povezanost računalnih znanosti i humanistike, čime se ujedno nastojalo pokazati kako je HR legitimna akademska aktivnost, kako je broj kolegija iz područja bilježio porast na sveučilištima diljem Sjeverne Amerike, ali se ukazivalo i na sve veći rast sveučilišnih centara. Drugi je, pak, zahtjev podrazumijevao upravo važnost poveznice između računalnih metoda i tradicionalnih humanističkih istraživanja, čime se nastojalo ukazati na važnost alata primjerenih za provođenje visokokvalitetnih istraživanja (Ide 1987, str. 211). Svi izlagači koji su sudjelovali u navedenoj radionici složili su se kako bi svaki oblik edukacije o računalstvu i humanistici trebao uključivati pregled relevantnih aplikacija važnih za humanistička istraživanja ali i edukaciju o uporabi tih aplikacija, dok su pojedinci ukazivali i na značaj kvantitativne metodologije. Što se tiče pregleda relevantnih aplikacija, on se ne bi trebao temeljiti samo na općem pregledu inače svojstvenom edukacijama iz informatičke pismenosti, iz razloga što je studentima potrebna dublja ideja o metodologiji koju je moguće primijeniti korištenjem različitih aplikacija i u kontekstu specifičnosti pojedinih istraživanja. Ovdje je bilo riječi o svojevrsnom holističkom pristupu u kojem je upravo pitanje metodologije bilo iznimno važno pa se ukazivalo i na značaj tradicionalnih metoda relevantnih za humanističke discipline. Drugim riječima, materijal relevantan za lingvistiku, kognitivnu psihologiju i umjetnu inteligenciju mogao bi biti od iznimnog

značaja za razumijevanje tehnika za stilističku i semantičku analizu ili analizu sadržaja (str. 213).

Navedeni stavovi nadopunjavali su se i nešto drugačijim zahtjevima koji nisu u toj mjeri podcrtavali metodološke postupke, koliko konkretne računalne metode. Navedeno je otvorilo diskusiju o potrebi poznavanja programskih jezika (npr. tada aktualnih Basica, Pascala, SNOBOL-a, Prologa, Lispa) i programiranja pa je razvidno kako su se iskristalizirala dva smjera koja su se razlikovala s obzirom na razinu skupa računalnih znanja i vještina koje bi studenti humanistike trebali usvojiti za uspješno i kvalitetno provođenje humanističkih istraživanja. U prvoj skupini okupili su se oni koji su smatrali kako je osnovna informatička pismenost sasvim dostatna, dok su drugi smatrali kako je dublje poznavanje informatike i računalstva, a posebice znanje programiranja i primjena algoritma neophodno za provedbu kvalitetnih istraživačkih zadataka. Međutim, bez obzira na ova različita stajališta svi su složili kako bi studentima humanistike trebalo osigurati barem razumijevanje temeljnih računalnih koncepata, kao što su primjerice poznavanje programske petlje, ali i onih nešto složenijih (npr. organizacija i pristup informacijama) kao neophodnih elemenata za razumijevanje računalnih operacija i formalnih procesa i metoda nužnih za provedbu humanističkih istraživanja u računalnom ozračju.

Rasprave koje su se vodile i nakon radionice održane na Vassar Collegu nisu do kraja riješile problematiku osmišljavanja studijskih programa u humanističkom području s naglašenom komponentom informacijsko-komunikacijskih tehnologija. No, krajem devedesetih godina prošloga stoljeća akademski su se

programi ipak počeli uvoditi što može biti pokazatelj prihvaćanja HR-a od strane šire akademske zajednice. U tom kontekstu treba izdvojiti preddiplomski studij iz primijenjenog računalstva s nizom humanističkih disciplina na King's Collegeu u Londonu, ali i diplomski studij sa sjedištem u Centru za humanističko računalstvo. Sveučilište Alberta jedno je od prvih sveučilišta koje je pokrenulo program pod nazivom *Humanities Computing*, dok je Sveučilište u Glasgowu pokrenulo program pod nazivom *History and Computing*.

Činjenica jest da su vremenom tehnologije napredovale i da ono što je u tom smislu bilo aktualno prije pet, deset godina (u hardverskom i softverskom smislu), danas je zastarjelo. Jednako tako, dolaskom novih generacija studenata značajno se mijenja i predznanje koje u području novih tehnologija posjeduju, podiže se razina informacijske i informatičke pismenosti pa je i u tom smislu edukacije potrebno konstantno usklađivati i osvježavati. Ono što vidimo kao jedno od suštinskih pitanja u diskusiji o obrazovanju humanista odnosi se na problematiku organizacije studijskih programa. U tom smislu, držimo kako je tradicionalni teorijsko-metodološki okvir potrebno zadržati, ali ga je i to posebno podcrtavamo, važno nadopuniti skupom znanja i vještina iz područja računalstva koji su neophodni za provedbu istraživanja potpomognutih tehnologijama. Na pitanje koja su to konkretno znanja i vještine koje bi studenti i znanstvenici u humanističkom području trebali posjedovati dijelom ćemo odgovoriti drugim dijelom knjige kojim donosimo prikaz i opis odabranih alata za koje držimo da bi ih u kontekstu specifičnosti istraživačkoga problema trebalo poznavati.

Problemi definiranja i pozicioniranja humanističkoga računalstva kao discipline

Tijekom kasnih devedesetih godina 20. stoljeća znanstvena je literatura mahom orijentirana na pokušaj definiranja i kategoriziranja područja humanističkoga računalstva. Navedeno dolazi do izražaja i u seminaru kojega je Geoffrey Rockwell 1999. godine pod nazivom *Is Humanities Computing an Academic Discipline?* održao na Institute for Advanced Technology in the Humanities. Ovaj je članak potom objavljen i u knjizi *Defining Digital Humanities. A Reader*, urednika Melisse Terras, Julianne Nyhan i Edwarda Vanhouttea, 2013. godine. Neke od temeljnih i osobito zanimljivih teza koje Rockwell iznosi u ovom članku uglavnom se koncentriraju oko pokušaja odgovora na sljedeća pitanja: *je li humanističko računalstvo akademska disciplina?*, *je li humanističko računalstvo područje pogodno za poučavanje?*, *zašto bi trebali biti zabrinuti oko pitanja administriranja ovoga područja?*, *je li riječ o znanstveno-istraživačkom području?* U tom smislu Rockwell nudi i niz odgovora koje smatramo važnima u pokušaju sintetiziranja nekih značajnih odrednica vezanih uz ovu disciplinu. Nadalje, Svensson (2016) ulazi dublje u problematiku te nastoji ukazati na činjenicu kako se u literaturi nerijetko miješaju pojmovi *disciplina*, *područje*, *oblast*. No, istraživanje koje je proveo pokazalo je kako se ipak najčešće u kontekstu digitalne humanistike govori o *disciplini* i *oblasti*, a manje o *području* što nije za čuditi s obzirom da su ovi češće korišteni pojmovi generički i nisu opterećeni dozom institucionalnosti koju pojam *područje* podrazumijeva. Akademska su područja, naime, povijesna, kontekstualna i dinamična, te su

upravljena institucijskom, društvenom i kulturnom logikom (str. 36).¹³

DH, dakle, možemo smatrati akademskom disciplinom u slučaju da o njoj mislimo, ali i da je u kontekstu visokoga obrazovanja i klasifikacije znanstvenih područja kao takvu i prihvatimo. O njezinu statusu, stoga, valja raspraviti u formalno-pravnom kontekstu. Problematika obrazovanja i uvođenja računalnih znanosti u studijske programe društveno-humanističkoga usmjerenja pokazuje se kao iznimno osjetljiva, ali i važna. Niz je nedoumica oko pitanja što bi studenti dobili predmetima iz ovoga područja, te kako na najbolji mogući način teme i problematiku DH-a implementirati u studijske programe. Ono što dodatno komplicira cijelu sliku jest postojanje niza poddisciplina i zajednice istraživača oko njih okupljenih. Iznijeto je tako u uskoj vezi s formalno-pravnim zaprekama, ali i propisima koji proizlaze iz klasifikacije znanstvenih područja. Status svake discipline ovisi o upravo u zdravom administrativnom, formalno-pravnom i akademskom ozračju. Iz toga bi razloga humanističko računalstvo, tj. digitalnu humanistiku valjalo na prihvatljiv način implementirati u postojeći obrazovni sustav, predvidjeti sredstva za financiranje projekata iz područja, ali, i najvažnije, osposobiti i ohrabriti znanstvenike za provedbu istraživanja u području posebno s obzirom na činjenicu da se

¹³ Zanimljivo je istaknuti kako je organizacija nekoga područja po disciplinama zapravo relativno novi fenomen koji potječe negdje od početka 19. st. kada je Peter Weingart odredio discipline društvenim zajednicama i povijesnim konstruktima. Ne postoji nekakav shematski plan temeljem kojega bi se jasno moglo ustanoviti što uistinu neku disciplinu čini akademskom disciplinom, no činjenica jest da digitalna humanistika ispunjava stanovite kriterije temeljem kojih se može identificirati upravo kao akademska disciplina (Svensson 2016, str. 40).

istraživački projekti ne bi trebali orijentirati na teoretiziranje o utjecaju računala na humanističke znanosti, nego bi se prvenstveno trebali usredotočiti na njihovu primjenu u kontekstu konkretnih istraživačkih pitanja.

Problemi oko pokušaja određenja preciznijega mjesta DH-a, proizlaze jednim dijelom, kako to dobro primjećuje Vanhoutte (2013) iz razloga što HR nije bilo niti predmet istraživanja humanističkih, a niti računalnih znanosti. U tome i treba tražiti objašnjenje zašto je tijekom vremena pitanje konstituiranja i definiranja ove discipline postalo istraživačko pitanje brojnih rasprava (str. 120). Pronalaženje zajedničke prakse teorijskih principa, metodologije, ali i filozofije u kontekstu humanističkih disciplina u kojima su se angažirali informatičari i inženjeri računalstva pokazalo se i ne toliko jednostavnim u pokušaju definiranja discipline. Sumnje u validnu, distinktivnu i koherentnu disciplinu koje su rasle od 1980-ih godina i dalje su postojale. Tako je povijest HR-a dugo bila povijest problema istraživanja, kao što što su primjerice uređivanje elektroničkoga teksta, naratološki i multimedijски studiji ili upotreba računala u disciplinama poput povijesti, muzikologije, leksikografije i izvedbenim umjetnostima. No, izoliranost navedenih, ali i sličnih istraživanja utrla je put svojevrsnom redefiniranju, prije rebrendiranja HR-a, što se očitovalo uvođenjem nešto apstraktnijega termina *digitalna humanistika* koji je generirao nove interese za područje, osobito kod šire publike (str. 136). No, što je ova promjena naziva u suštini značila? Prema nekim autorima, među kojima valja izdvojiti i Vanhouttea, riječ je tek o zamijeni hermetične aktivnosti koja je karakterizirala HR nešto zgodnijom, gotovo *hipsterskom* kvalifikacijom. U suštini, ništa se bitno nije

promijenilo, a stari su problemi i dalje ostali. Međutim, ovdje valja biti oprezan jer će upravo naše izlaganje pokazati kako HR valja držati pokretačem promjena koje su pod utjecajem tehnologija zahvatile humanistiku. Razvojem tehnologija u povijesnom kontekstu, mijenjale su se i metode i principi onih humanističkih istraživanja koja su pretendirala poveznici s računalstvom. Stoga prijelaz iz humanistike u HR možemo shvatiti kao prirodni i logični slijed razvoja znanosti koji prati promjene u području tehnologija.

Nadalje, McCarty (2005) je nastojao analizirati metodu HR-a u četiri perspektive: analiza, sinteza, kontekst i profesija (str. 26). Analiza i sinteza konvencionalne su metode svih humanističkih disciplina, a s obzirom da je, kako smatra McCarty, HR disciplina humanističkih znanosti, njegove se opće metode u principu ne razlikuju od ostalih disciplina. Računalni aspekt nudi istraživačima razvoj vlastitih analitičkih pristupa. Razlika između računalstva za humanistiku i računalstva u humanistici jest upravo manjak, ali istodobno i iznimna važnost u modeliranju¹⁴ kao esencijalnoj analitičkoj metodi u brojnim oblicima računalstva.

Metode koje dijele humanističke discipline i računalna znanost, prema Thalleru (1999) i Orlandu (2002) koji uzgred budi rečeno disciplinu nazivaju *humanističkim računalnim znanostima* ili *humanističkom informatikom*, moraju biti usmjerene povećanju znanja koje karakterizira određenu disciplinu te prema snažnijoj identifikaciji s računalnim znanostima. Formalizacija problema putem algoritama i predstavljanja podataka središnje su metode

¹⁴ Pod *modeliranje* McCarty (2005) podrazumijeva heuristički proces konstrukcije i manipuliranja modelima. Model je za njega ili reprezentacija svrhe istraživanja ili dizajn za realizaciju nečega novoga (str. 24).

računalstva u humanistici. S druge strane, postoje pak autori među kojima se ističe primjerice Lou Bernard, koji upozoravaju, a s kojima će se također veliki broj „tradicionalnih“ humanista složiti, kako se humanistička istraživanja ne mogu metodološki formalizirati. Iz toga razloga u središte HR-a postavlja hermeneutiku i kodiranje teksta kao dvije metode koje u principu nisu svojstvene drugim znanostima (Bernard citirano Vanhoutte 2012, str. 158). Kao početnu točku hermeneutičkoga kontinuuma Bernard postavlja transkripciju i uređivanje teksta kao odlučujuće, ali i subjektivne činove tumačenja. Tako mogućnost označavanja u svrhu artikulacije i dokumentacije različitih semiotičkih sistema u tekstu, omogućuje humanistima jednostavno predstavljanje složene slojevitosti teksta, kao i međusobnu povezanost svih aspekata hermeneutičke analize, čime se u konačnici značajno olakšava polivalentna analiza (isto). U tom smislu TEI se pojavljuje kao mogućnost koja osigurava humanistima modele za označavanje, odnosno artikulaciju, dokumentaciju, ali i reprezentaciju različitih interpretacija na tekstu te omogućuje eksplicitnu teoriju teksta.

O problemu definiranja i pozicioniranja discipline raspravlja i Melissa Terras u članku naslovljenu *Disciplined: Using Educational Studies to Analyse 'Humanities Computing'*. godine. Ovaj je članak prvi put objavljen 2006. godine u časopisu *Literary and Linguistic Computing*. Terras zastupa tezu prema kojoj je riječ o relativno mladoj disciplini za koju još uvijek ne postoji konkretna definicija te ističe kako se brojne rasprave uglavnom usredotočuju na praktični i pragmatičnu perspektivu u kontekstu same discipline. U pokušaju približega određenja pojma *humanističko računalstvo*, smatra kako je riječ o akademskim aktivnostima koje se nerijetko okupljaju

oko specifičnih aplikacija i alata koji se izrađuju i upotrebljavaju u analizi velikih korpusa tekstova, konstrukciji digitalnih edicija uglavnom iz područja književnosti, izradi digitalnih artefakata tijekom procesa digitalizacije, upotrebi virtualne realnosti za rekonstrukciju modela u arhitekturi, itd. Nove tehnike i tehnologija kontinuirano se razvijaju te se implementiraju u humanistiku, no bez obzira na navedeno, iznimno je problematično ono što ova autorica naziva HR, a jednako se odnosi i na drugi najčešće korišteni pojam, pojam digitalna humanistika, definirati akademskom disciplinom. Jednako tako, postoji tek nekolicina fakultetskih/sveučilišnih odsjeka u području, a većina je istraživača usmjerena uglavnom na rad na projektima, te se nerijetko (a posebice se to odnosi na sveučilišnu sredinu) na računalnu humanistiku gleda kao na tehničku podršku „pravim“ humanističkim istraživanjima. Postojanje relativno malog broja studijskih programa govori u prilog tvrdnji kako je iznimno teško odrediti skup vještina koje bi student humanističkih znanosti trebao tijekom obrazovanja steći.¹⁵ Upravo se iz toga razloga znatno lakše usredotočiti na radionice, edukacije ili programe cjeloživotnoga učenja kojima bi se osiguralo stjecanje znanja i vještina iz specifičnih i točno definiranih tema iz područja računalnih tehnologija, a koje onda znanstvenici mogu primjenjivati u vlastitim istraživanjima (Terras 2013, str. 69). Sljedeći problem na koji ukazuje ova autorica odnosi se na pitanje metodologije te iznosi kako discipline uobičajeno posjeduju dis-

¹⁵ Godine 2001. održana je konferencija upravo na temu obrazovanja u području digitalne humanistike, *The Humanities Computing Curriculum: The Computing Curriculum in the Arts and Humanities*; Malaspina University College, Nanaimo, British Columbia, Canada.

tinktivne metodološke pristupe, kao i teoretske i konceptualne okvire. Niti ovdje nije moguće iznijeti jedinstvene stavove kojima bi se ukazalo na postojanje stabilnoga teorijsko-metodološkog okvira unutar kojih se raspravlja o aktualnim problemima. No, pitanje je li takvo što uopće neophodno. Jer, u slučaju da postoji zajednica istraživača okupljenih oko određenoga problema, u slučaju da se stanoviti pomaci u kontekstu obrazovanja ipak događaju, u slučaju da postoje respektabilni časopisi i izdanja koja objavljuju ugledna sveučilišta, u slučaju da respektabilna svjetska sveučilišta pokreću centre i laboratorije te objavljuju natječaje za sudjelovanje u projektima—tada je zasigurno riječ o važnoj temi koju treba nastaviti promišljati i dalje znanstveno obrazlagati.

Digitalna humanistika

U prethodnom poglavlju nastojali smo ukazati na niz tehnoloških, društveno-kulturnih, ali i akademskih nastojanja oko uvođenja novih, tehnološki orijentiranih tendencija u područje humanističkih znanosti. To novo ozračje koje, kako smo istaknuli, postaje evidentno u godinama nakon Drugoga svjetskoga rata rezultiralo je formiranjem nove discipline, humanističkoga računalstva. Nerijetko se u literaturi ovo razdoblje izjednačava s takozvanim prvim valom digitalne humanistike, a koji je bio kvantitativan, usmjeren na izradu i pretraživanje baza podataka, orijentiran automatizaciji korpusa lingvistike. Za razliku od navedenoga, drugi val je kvalitativan, interpretativan, eksperimentalan, emotivan i generativan u karakteru.¹⁶ Usmjerava se prema korištenju digitalnih alata koji pretendiraju postati temeljem metodološke snage, te se fokusira na kompleksnost i specifičnost

¹⁶ U literaturi se, osim prvog i drugoga vala govori još i o dvije faze digitalne humanistike. Davidson (2008) primjerice razlikuje Humanistiku 1.0 i Humanistiku 2.0, nadovezujući se na distinkciju Weba 1.0 i Weba 2.0. Kaže kako se Humanistika 2.0 razlikuje od prve na podacima utemeljene generacije ne samo po interaktivnosti, nego i po postojanju različitih teorijskih okvira koji decentriraju znanje i autoritete (Davidson 2008 citirano u Svensson 2010, str. 16). Nadalje, prema Berryju (2011), prvom valu svojstvena je izgradnja infrastrukture kroz, primjerice, digitalne repozitorije. Drugi val širi spoznaje granice arhiva, uključuje digitalna (ne digitalizirana) djela pa osobiti istraživački značaj dobiva elektronička literatura, interaktivna fikcija, mrežni artefakti (str. 4). Berry razlikuje i treći val/sloj koji je orijentiran razmatranju zapravo digitalne komponente u kontekstu digitalne humanistike, i koji se usredotočuje na specifičnosti medija i načina na koje medijske promjene utječu na epistemološke promjene (isto.) Riječ je o pravcu koji izrasta iz tzv. studija softvera (*software studies*) i kritičkih studija kôda (*critical code studies*), a koje je inicirao Lev Manovich (2013) svojom studijom naslovljenom *Software Takes Command*. Ovaj treći val u literaturi se izjednačuje s terminom *računalni obrat* (engl. *computational turn*).

različitih medija, na povijesni sadržaj, analitičku dubinu, kritiku i interpretaciju. Mi ćemo, a potaknuti Berryjevim stavovima (2012) koji kritizira podjelu računalno orijentiranih istraživanja u humanistici na *valove* te sugerira upotrebu termina *slojevi*, izbjegavati korištenje obaju navedenih pojmova iz razloga što smatramo kako je riječ o kontinuiranom razvojnem procesu kojega karakteriziraju nastojanja oko stvaranja jednoga novog ogranka u kontekstu humanističkih istraživanja i koji bez obzira na svu svoju složenost i heterogenost ipak pokazuje tendenciju prema uspostavljanju kakve-takve komplementarnosti.

Držimo, međutim, kako je općenito govoreći moguće izdvojiti dva pristupa u shvaćanju digitalne humanistike. Prvim pristupom nastoji se pokazati kako je sve značajnija uloga digitalnih tehnologija u suvremenoj kulturi doprinijela razvoju novi oblika istraživanja, novih načina u pristupu i organizacija znanja i novim formama kulturne komunikacije. Temeljna pitanja koja postavljaju humanističke discipline, promijenila su se. Promijenio se način na koji u digitalnom dobu čitamo i pišemo; raspravlja se o novim formama kulturnog izričaja koje upravo zahvaljujući digitalnoj komponenti doživljaju nagli rast. Jednako tako, govori se i o odnosu tih novih kulturno-umjetničkih nastojanja i tradicije; nastoje se procijeniti etičke i političke implikacije digitalnih tehnologija; istražuju se alati i načini njihova razvoja u kontekstu visoke razine upotrebljivosti, itd. Ovaj pristup karakterizira snažna povezanost s humanističkim disciplinama, ali je evidentna i ona struja koje poziva na hitnu rekonfiguraciju „tradicionalne“ humanistike. Tehnologije se, čak i u slučaju da postoji interes za njihovom praktičnom primjenom pojavljuju u prvom redu kao objekt istraživanja. Drugo

određenje nešto je više statično te su u središtu upravo tehnologije, tj. istraživanja kojima se nastoji otkriti što se to događa u slučaju suodnosa i presijecanja računalnih alata s kulturnim artefaktima bilo koje vrste. Usredotočuje se na ispitivanje alata u stvaranju novoga znanja, te se orijentira prema osposobljavanju studenata za analizu problema u ozračju digitalnih metoda (Svensson 2010, str. 31). Riječ je o dvjema orijentacijama koje supostoje još od samih početaka razvoja discipline, od kojih je jedna više teorijski usmjerena, a drugu karakterizira prvenstveno praktična upotreba konkretnih alata. Svakako, valja upozoriti kako DH nije u opoziciji s prošlošću, upravo suprotno, ona iz te prošlosti izrasta. Odaje priznanje pionirskim laboratorijima nastalim tijekom posljednjih sedam desetljeća, a koji su pridonijeli implementaciji primjerice statističke obrade (računalna lingvistika), povezivanja (hipertekst), modeliranja (vizualni prikazi), stvaranja strukturiranih podataka (XML), itd. u područje koje je po svojoj prirodi primarno kvalitativno. No, ono po čemu se DH bazično razlikuje od u prethodnom poglavlju predstavljenih najranijih znanstveno-istraživačkih usmjerenja, odnosi se prije svega na usredotočenost na analizu digitalnih/digitaliziranih izvora te se više ne zaokupljuje u istoj mjeri mogućnostima koje pruža primjerice organizacija kakvoga repozitorija. Inspirirana misljuje kako računalni alati imaju potencijala transformirati sadržaj, metodologiju, ali i djelokrug humanističkih istraživanja, DH se prvenstveno usmjeruje prema novim praksama.

Otvaraju se i brojna pitanja o budućnosti humanistike općenito, kao i o ulozi DH u kontekstu kreiranja novih istraživačkih pravaca svojstvenih suvremenoj kulturi i umjetnosti. Dakako, na

mnoga je pitanja još uvijek nemoguće ponuditi jednoznačno rješenje, no činjenica jest kako se, a posebice se to odnosi na međunarodni gospodarski i znanstveno-istraživački prostor upravo DH izdvaja kao disciplina koja ima potencijala utjecati primjerice na povećanje stope zaposlenosti u području kulture i umjetnosti, ali i kao područje koje može doprinijeti osuvremenjivanju tradicionalnih pristupa u istraživanju humanističkih pitanja. Potencijal je, svakako, i u elektroničkom izdavaštvu, elektroničkim knjigama, kao i zabavljačkoj industriji posebice s obzirom na evidentni porast *streaming* servisa. Nije stoga naodmet ponoviti kako živimo u dobu poništavanja granica između sveučilišta, muzeja, arhiva i knjižnica kojima se sugeriraju posve drugačije mogućnosti i inovativni istraživački smjerovi. Nagli razvoj i upotreba tehnologija u svrhu dostizanja ovih ciljeva omogućuju široj publici upoznavanje s novim tendencijama pa u tom kontekstu upravo DH vidimo kao usmjerenje koje može pridonijeti značajnijoj popularizaciji onih područja koja su se do ne tako davno smatrala izdvojenima i namijenjenima samo odabranim, elitnim slojevima društva.

Okvir za definiranje digitalne humanistike kao samostalne discipline

Kirschenbaum (2012) u članku naslovljenu *What is Digital Humanities and What's It Doing in English Departments?*, nastojeći obrazložiti status digitalne humanistike u kontekstu humanističkih istraživanja te objašnjavajući razloge implementiranja ove discipline u filološke studijske programe, zapravo implicite odgovara i na prvi dio pitanja iz naslovne sintagme. Moguće je, naime,

o digitalnoj humanistici, a na što ćemo se osvrnuti i u nastavku, govoriti u kontekstu multimedije, medijskih studija, vizualnih komunikacija, itd. No, činjenica jest da se povezivanje računalstva i područja kulture i umjetnosti prvotno veže uz filološke odsjeke, uz lingvistiku i stilistiku, odnosno uz discipline vezane za istraživanja jezika i teksta. S obzirom na mogućnosti svojstvene najranijim računalnim sustavima, nije za čuditi što je humanističko računalstvo u prvome redu bilo orijentirano na tekst. Toj povezanosti teksta i informacijsko-komunikacijskih tehnologija svjedoči, potom, i razvoj elektroničke knjige, ali i sve veći interes za e-čitanje, *e-book* uređaje poput Kindlea, iPada, Nooka, te pokretanje velikih projekata digitalizacije građe među kojima se, u međunarodnim okvirima, osobito ističe Googleova tražilica knjiga, *Google Books*.¹⁷ Digitalna i digitalizirana tekstualna građa omogućila je istraživačima rad na velikom broju podataka te ih je potaknula na osmišljavanje novih metoda. Tako je i Franco Moretti razvio metodu udaljenoga čitanja (*distant reading*) i vizualizacije informacija, a koja omogućuje „čitanje“ tisuća, čak i milijuna knjiga istodobno (str. 202).

Zaokupljenost metodom i načinima predstavljanja rezultata istraživanja utjecali su na brojne humaniste pa nije za čuditi kako veliki broj znanstvenika na digitalnu humanistiku gleda kao na skup metodoloških praksi koje računalne alate približavaju tradicionalnom istraživačkom radu humanista. Računalni znanstvenici, pak, na digitalnu humanistiku gledaju kao na studije različitih računalnih formi koje utječu na humanistiku uopće, no

¹⁷ Činjenica jest da je veći broj knjiga koji je pohranjen u ovu Googleovu digitalnu bazu podataka pisan na engleskom jeziku, a što onda predstavlja prepreku za istraživanje većine nacionalnih filologija.

u digitalnoj humanistici jednako tako vide i snažan potencijal za unaprjeđenje znanja uopće.

Upravo zbog širine i niza mogućnosti koje ova disciplina istraživačima u različitim humanističkim područjima otvara, i nije tako jednostavno i jednoznačno odgovoriti na pitanje što je to digitalna humanistika. U tom nam je smislu zanimljivo ukazati na poglavlje u publikaciji *Debates in the Digital Humanities* (2015) koje sadrži čak dvadeset i jednu definiciju digitalne humanistike. Popis je skraćena lista definicija pronađenih na internetu, a među kojima Gardiner i Musto osobitu pažnju posvećuju dvama određenjima. Prema Wikipediji DH je područje istraživanja i poučavanja u kojem se računalstvo isprepliće s humanističkim disciplinama. Razvijena iz HR-a i digitalno-humanističke prakse, DH okuplja različite teme, od okupljanja različitih artefakata na internetu do *rudarenja* velike količine kulturnih podataka. Okuplja digitalizirane i digitalne materijale i kombinira metodologije tradicionalne humanistike i društvenih znanosti s digitalnim izdavaštvom i računalnim alatima, kao što su vizualizacija podataka, dohvaćanje informacija, statistika, *rudarenje* teksta, itd. Za razliku od navedenoga, Burdick (2012) donosi nešto drugačije objašnjenje te smatra kako se DH zaokupljuje pitanjem pozicije čovjeka u umreženom, informacijskom dobu; postavlja i odgovara na istraživačka pitanja koja se ne mogu svesti na jedan žanr, medij, disciplinu ili instituciju. Riječ je o globalnom, transpovijesnom i transmedijskom pristupu u stvaranju znanja i značenja (Burdick 2012 citirano u Gardiner i Musto 2015, str. 305). Navedene definicije najbolje pokazuju dva najpopularnija modela u pokušaju pobližega određenja discipline, jednoga koji značajnije pretendira

računalnoj perspektivi, i drugoga nešto naglašenije filozofske, općenite orijentacije. No, s obzirom na činjenicu da je element digitalnoga prisutan u oba pogleda sasvim je jasno kako upravo ovaj element i utječe na oblikovanje suvremenih znanstveno-istraživačkih pristupa u humanističkim znanostima.

Bilo kako bilo, riječ je o disciplini koja uključuje konvergentne prakse i to prvenstveno one koje istražuju ozračje u kojem tisak više nije primarni medij za produkciju i diseminaciju znanja. Digitalni alati, tehnike i mediji premašili su tradicionalne koncepte znanja u kontekstu digitalne humanistike nije sve u tom toliko spominjanom *digitalnom* u smislu kakvoga ograničavajućega opsega istraživačkoga korpusa koji bi se sveo isključivo na proučavanje tzv. digitalne kulture. Jednako tako, promišljajući o DH ne možemo fokus usmjeriti niti isključivo na drugi dio sintagme, tj. na *humanistiku* pa se orijentirati isključivo na traženje mogućnosti i načina za redefiniranje tradicionalnih praksi. Na tragu Burdick i sur. (2012) radije ćemo kazati kako je u kontekstu digitalne humanistike riječ o *mogućnostima* i *izazovima* koji izrastaju iz spoja termina *digitalno* i *humanističko* u novu kovanicu koja, bez obzira što je dvosmislena i što neosporno posjeduje manjkavosti u svojoj suštini priziva jedinstvo u različitosti. *Mogućnosti* tako uključuju ako ne brisanje, onda barem pomicanje granica između humanističkih disciplina, društvenih znanosti, umjetnosti, ali i prirodnih znanosti. Donose nove istraživačke forme, produkciju znanja, otvaraju prostor za obrazovanje budućih naraštaja humanista u istraživačkom, na projektima orijentiranom učenju i poučavanju te pridonose razvoju praksi kojima je cilj podizanje kvalitete i vidljivosti istraživanja u području. *Izazovi*, pak, podra-

zumijevaju pokušaj iznalaženja odgovora na neka temeljna pitanja, kao što su npr. kako tradicionalne istraživačke vještine prilagoditi multimedijском okruženju?; kako će i tko će konture kulturnog i povijesnog pamćenja definirati u digitalnoj eri?; kako će se prakse poput primjerice digitalnoga pripovijedanja podudarati ili razlikovati od usmenoga ili pisanoga pripovijedanja?; kako definirati mjesto humanističkoga (ali i humanoga) u umreženom svijetu (str. 122)?

Era računala i novih tehnologija započinje svoj razvojni put, već smo istaknuli, od Drugoga svjetskog rata, međutim nakon uvođenja osobnih računala, World Wide Weba, mobilne komunikacije i društvenih medija digitalna je revolucija orijentiravši se stvaranju nove, globalizirane javne sfere i novih mogućnosti u stvaranju i diseminaciji znanja ušla u posve novu fazu. Izrasla, manje-više na prvoj računalno orijentiranoj generaciji humanistike, digitalna se humanistika sve više okreće elektronički inflektivnom jeziku 21. stoljeća te se približava nepokretnim i pokretnim slikama i zvuku. Jednako tako, danas se sve više mijenja i uloga koju je, kako smo prethodno istaknuli, posjedovao tekst pa unatoč prilično široko orijentiranim počecima humanističkoga računalstva, i to od studija koje istražuju frekvenciju riječi i tekstualnih analiza (klasifikacijski sistemi, kodiranje) do uređivanja hiperteksta i izrade baza podataka—digitalna humanistika umanjuje privilegirani status kakav je uživao tekst. Sve se više usmjeruje prema grafičkim metodama u predstavljanju i organizaciji znanja, prema dizajnu kao integralnoj komponenti pretraživanja, transmedijalnosti, itd. Prema Burdick i sur. (2012) karakterizira je fokus na izradu alata, okruženja i platformi za kolaborativni istraživački rad. Upravo

je desktop okruženje sa svojim grafičkim korisničkim sučeljem i WYSIWYG alatom u stvarnom vremenu utjecalo kako na ekspanziju korpusa digitalnih/digitaliziranih dokumenata, tako je dovelo i do postupne integracije zvuka, videa i grafike. Ova se integracija posebno razvila tijekom posljednjih desetljeća te je omogućila da tzv. internetska kultura u potpunosti izrazi svoj multimedijalni karakter. Također, pogodovala je poboljšanju modela dijeljenja, zajedničkog stvaranja, objavljivanja i izgradnje zajednice koja je smjestila internet u središte suvremenih društvenih rasprava i društveno-ekonomskih procesa. Koncept interneta kao javne sfere koja funkcionira kao produžetak fizičkoga javnoga prostora suvremenoga života intenzivirana je, dakako, razvojem pametnih telefona, tableta i ostalih sveprisutnih računalnih i drugih medijskih uređaja.

U pokušaju određenja i pobližega predstavljanja digitalne humanistike valja biti oprezan i kazati kako tek puka upotreba digitalnih alata u svrhu humanističkih istraživanja ne predstavlja sama po sebi digitalnu humanistiku. Ne bi je trebalo shvatiti niti studijima digitalnih artefakata, novih medija i suvremene kulture u ozračju u kojem bi „digitalno“, „novo“, „mediji“ predstavljali tek distinktivno obilježje u odnosu na istraživanja usmjerena analizi fizičkih artefakata, tradicionalnih medija i povijesti kulture. Upravo suprotno. Digitalna humanistika razumije objekt istraživanja kao cjelokupnu ljudski zapis, od pretpovijesnih vremena do danas pa je upravo u tome razlog zbog kojega klasične discipline igraju jednako tako važnu ulogu u razvoju digitalne humanistike kao primjerice i studiji novih medija. To je ujedno i razlog zbog kojega istraživanja katkada izlaze izvan tradicionalnih okvira i posežu za

kvantitativnim metodama svojstvenim društvenim i prirodnim znanostima, kao i za tehnikama i načinima mišljenja koji primarno potječu iz umjetničkoga područja. U tom je smislu zanimljivo istaknuti mišljenje O'Donnella (2016) prema kojem je DH možda najbolje shvatiti kao paradisciplinu koja uključuje skup pristupa, vještina, zanimanja i vjerovanja koje dobivaju svoje značenje iz povezanosti s drugim vrstama znanja i praksi. Postati digitalni humanist nikako ne znači ostaviti svoja prethodna zanimanja, ali svakako iz temelja treba promijeniti načine pristupanja problemu. Prema tome, i te kako je moguće biti oboje, i digitalni humanisti i „veliki teoretičar“, kao što je moguće biti i digitalni humanist, kritičar teksta, filolog, povjesničar i arheolog (O'Donnell 2012 citirano u O'Donnell i sur. 2016, str. 496).

Terminološki problemi

Prema Vanhoutteu (2013) digitalna humanistika jest termin koji definitivno nije u potpunosti zamijenio ono što je prethodno označavalo humanističko računalstvo. Očito je da postoji stanovito zajedničko razumijevanje oko termina koji se referira na humanistička istraživanja u digitalnom dobu, no popularnost ovoga termina odvodi nas u opasnost od njegove trivijalizacije, posebice iz razloga što katkada nije posve jasno na što se pojam „digitalno“ odnosi. Je li riječ o digitalnim izvorima koji predstavljaju temelje analize, je li riječ o upotrebi alata u analizi, ili se pak ono odnosi na oboje? Detaljnije ulaženje u pokušaj određenja pojma „digitalno“ može postati samo zamršenije i čini se da neće riješiti pokušaj jedinstvenoga određenja discipline. Veliki broj znanstvenika drži kako je HR bilo hermetički termin

pa u tom kontekstu onda djeluje kako se digitalna humanistika referira na nešto jasniji opseg. Humanističko računalstvo odnosilo se na svojevrsno raskrižje na kojem su se informatika i informacijske znanosti susretale s humanistikom, a njegova se povijest uglavnom povezuje s leksičkom tekstualnom analizom i strojnim prevođenjem. Digitalna se humanistika u principu ne odnosi na tako specijalizirane aktivnosti, nego prije osigurava široki prostor za različita digitalna istraživanja u humanistici. Međutim, i u kontekstu ovoga određenja pojavljuje se niz nedoumica, posebice zbog toga što su autori termina istaknuli kako je riječ o redefiniranju discipline i njezinom širenju na cijeli spektar onoga što se podrazumijeva pod pojmom multimedije. U tom kontekstu postaje nejasno hoćemo li discipline kao što su računalna lingvistika, multimedija i studije video igara podvući pod zajednički naziv digitalne humanistike. Bilo kako bilo, riječ je o hibridnom području, području koje prelazi granice i ulazi u područja drugih znanosti, ukida tradicionalna ograničenja između teorije i prakse, tehnološke implementacije i istraživačke refleksije.

U pokušaju terminološkoga određenja pojmova HR i DH razvidna su dva smjera. Prema jednom mišljenju digitalna humanistika nije ništa drugo no zamjena jednoga termina drugim, ljepšim i zvučnijim. Prema drugom mišljenju, npr. Svesnssonovu (2012) digitalna humanistika je širi pojam, pa za razliku od istraživanja usmjerenih uglavnom na tekst i znanstvene rasprave koje su u prvi plan postavile problem metodologije, ovo je mnogo širi pojam koji obuhvaća aktivnosti i strukture humanističkih znanosti i informacijskih tehnologija (str. 42). Digitalna humanistika ne odbacuje tekst, ali se istodobno hvata u koštac s činjenicom

da živimo u vremenu u kojem dominira vizualno, pa u svoja istraživanja uključuje računalne igre, internetske stranice, virtualne svjetove, društvene mreže, film i digitalnu umjetnost. Riječ je, dakle, o širenju predmeta istraživanja koje zahtjeva drugačije pristupe i metode, ali i značajniji angažman istraživača novih medija. Digitalna humanistika tako pretpostavlja razvoj i upotrebu alata usmjerenih istraživanju internetskoga života i kulture. U tom smislu Svensson otvara zanimljivu raspravu upravo u kontekstu razvoja i primjene različitih alata, i to od onih za sistematizaciju i kontekstualizaciju arhive elektroničke pošte, preko onih za prilagodbu istraživanja društvenih mreža potrebama humanistike do alata koji bi omogućili praćenje, označavanje i istraživanje multimedijalne komunikacije. Taj odnos između DH-a i novih medija Svensson drži osobito intrigantnim (str. 181).

Nestabilnosti teorijsko-metodološkoga okvira

Nerijetko se u literaturi raspravlja, a i mi smo već nekoliko puta spomenuli problem nepostojanja jasnoga teorijsko-metodološkoga okvira specifičnoga humanističkim znanostima. Dok društvene znanosti, ovisno o vrsti istraživanja posežu primjerice za etnografijom, intervjuom, anketom, fokus grupom, itd., postoje autori koji smatraju kako bi se i istraživanja u DH trebala provoditi na sličan način. Činjenica jest da većina digitalnih humanista ne poseže za kvalitativnim metodama, kao što su anketiranje, opažanje, intervjuiranje, i sl., pa i nije posve jasno mogu li se ove i slične metode inkorporirati u epistemološki okvir humanistike.

Jednako tako, digitalni humanisti koriste metode koje su uglavnom nepoznate humanistima pa se možda iz tog razloga ne može sa sigurnošću utvrditi kako ovi oblici istraživanja mapiraju teorijske okvire (Borgman 2015 citirano u Celement 2016:, str.153).

Znanstvenici koji području informacijskih sustava pristupaju iz očista društvenih znanosti, identificirali su u kontekstu vlastitih istraživanja tri pogleda na informaciju pa tako izlučuju: informaciju kao znanje, informaciju kao stvar, informaciju kao proces. Informacija kao znanje shvaća se kao nešto neopipljivo s obzirom da se temelji na osobnom, subjektivnom i konceptualnom razumijevanju. Informacija kao stvar posjeduje materijalnost, s obzirom da je predstavljena ili opisana na neki fizički način, bilo kao signal, tekst i sl., i to unutar nekoga sustava koji uglavnom uključuje računalne tehnologije. Prema tome, informacija kao stvar omogućuje znanstveniku u području društvenih znanosti izolirati informacijski objekt koji je povezan sa specifičnim oblicima informacijskoga rada iz sustava (bez obzira je li taj sustav digitalni ili nije) kao kulturne informacijske procese, kao što su primjerice skulpture, izložbe u muzejima i galerijama, knjige, dokumenti, itd. Istraživanje načina na koje znanstvenici stupaju u interakciju s i kroz informacijske objekte i sustave u kontekstu onih sredstava koja su na raspolaganju u domeni društvenih znanosti, nerijetko mnogo govori o načinima shvaćanja pojma informacije. Istodobno, veliki broj istraživanja u području društvenih, tj. informacijsko-komunikacijskih znanosti vođen je željom za boljim razumijevanjem informacije kao procesa. Riječ je o, kako bi rekao Foucault, *arheologiji znanja*, sistemima moći i utjecaja koji oblikuje informacijske sustave pa u tom smislu i proizvodnju

znanja, konstrukciju identiteta i intersubjektivnosti (Foucault 1968 citirano u Clement 2016: 154).

Druga, pak, skupina znanstvenika iz društvenoga područja drži kako je znanost rezultat neizrečene, ontološke, epistemološke i praktične različitosti suvremenoga doba. Njihove studije dijele zajednički teorijski okvir s humanističkim znanostima te uzimaju u obzir informaciju i proizvodnju znanja neovisno o tome što ih karakteriziraju različite metode istraživanja (Clement 2016, str. 155). Nadalje, kvalitativne metode u društvenim znanostima radije svoj fokus stavljaju na direktno promatranje, a ne na kakvo teorijsko obrazlaganje. Becker primjerice u poznatom eseju iz 1996. godine *The Epistemology of Qualitative Research* utvrđuje kako istraživači koji koriste kvantitativne metode opravdavaju rezultate istraživanja nastojeći dokazati kako su njihovi podaci pouzdani i ponovljivi. No, oni koji se baziraju na kvalitativnim metodama više su usredotočeni na točnost i preciznost vlastitih podataka. Drugim riječima, istraživači koji koriste neku od kvalitativnih metoda nastoje svoje podatke pokazati što objektivnijima kako bi kolege koji obično kvantitativne metode smatraju relevantnijima i njihove rezultate jednako tako smatrali vrijednima i točnima. U takvim studijama, artikulacija metodologije pomaže istraživačima ojačati sistematičnu prirodu vlastitih pristupa. No, podaci predstavljeni bez teorijskoga okvira drže se jednostavnim opisom i ne mogu biti kategorizirani kao znanstveni rad pa stoga tipičan model društvenih istraživanja jednako tako uključuje i eksplicitno iznošenje određene teorije. Teorija je opisana kao kontekst istraživanja, a može uključivati i objašnjenje njezina nastanka, kao i obrazloženja načina na koji se uklapa u konkretni istraživački problem. Slijedom navedenoga, nije

teško zaključiti kako je teorija ključna u epistemologiji društvenih znanosti i kako jamči znanstvenu legitimnost i objektivnost.

Partikularni interes digitalnih humanista jesu etnografske studije u kojima su objekt zanimanja tekst i tehnologije, a predmet istraživanja usmjeren je kreiranju i diseminaciji znanja. Digitalna humanistika, također, operira s informacijom kao stvari (riječ, stih, stranica, kôd), te istodobno shvaća informaciju kao proces, tj. kao kontinuirano stanje informiranja putem razumijevanja koje se stalno mijenja. Značaj informacije u kontekstu DH primarno se odnosi na kulturni kontekst koji onda utječe na promjenu tradicionalnoga razumijevanja proizvodnje znanja. Općenito govoreći digitalni humanisti tipični su predstavnici akademskoga intelektualizma, a njihov rad s informacijama uključuje istraživanje, pisanje, objavljivanje, konceptualizaciju projekata, poučavanja, itd. Pridružimo li navedenom značaj informacijsko-komunikacijskih tehnologija, tada se njihova aktivnost širi, između ostaloga, na razvoj i implementaciju algoritama, kodiranje, čuvanje podataka, upravljanje i analizu podataka, generiranje i analizu statistike, društveno umrežavanje, razvoj baza podataka, programa, interneta, razvoj vizualizacija i interpretacija, itd. Drugim riječima, rad s informacijama proces je stvaranja znanja koje su ugrađene u kulturu pa je popis mogućnosti koje su na raspolaganju DH-u gotovo beskonačan. Međutim, pođemo li od činjenice kako su digitalni humanisti humanisti obučeni za rad s informacijsko-komunikacijskim tehnologijama, ovdje se može otvoriti rasprava ne toliko o teorijskom okviru koji u humanističkim znanostima ima dugu tradiciju i predstavlja snažno uporište brojnim istraživanjima, koliko zapravo o metodologiji koju

ipak karakterizira stupanj fluidnosti. Područje DH jest ono koje eventualne nestabilnosti u metodološkim postupcima može prevladati pa je upravo u tu svrhu *The European Union's Digital Research Infrastructure for Arts and Humanities initiative* otišao korak dalje i predstavio tzv. TaDiRAH (*a Taxonomy of Digital Research Activities in the Humanities*), koji uključuje tri široko postavljene kategorije, a to su: *istraživačke aktivnosti, istraživački problem, istraživačke tehnike*. Istraživačke tehnike uključuju poveći popis tematskih područja, a koje se uglavnom odnose na čuvanje podataka, kodiranje, *gejmifikaciju*, modeliranje teme. Istraživačke aktivnosti uključuju dohvaćanje, stvaranje, analizu, interpretaciju, pohranu i diseminaciju. Istraživački problem znači odmicanje od usredotočenosti na sadržaj prema rješavanju konkretnoga pitanja na koji se nastoji primjenom različitih istraživačkih aktivnosti i tehnika ponuditi jednako tako konkretni odgovor.

U raspravi o metodološkim postupcima u DH ne možemo, kao primjerice u društvenim znanostima govoriti o kakvom definiranom skupu relevantnih metoda, kao što su npr. anketa, intervju, fokus grupa, itd. Razloge takvoga stanja valja tražiti s jedne strane u iznimno širokom području koje okuplja humanistika (filozofija, teologija, filologija, povijest, povijest umjetnosti, znanost o umjetnosti, arheologija, etnologija i antropologija, religijske znanosti, interdisciplinarnе humanističke znanosti¹⁸) i činjenici što svako od ovih područja posjeduje vlastite teorijsko-metodološke specifičnosti. S druge strane, a što je posljedica prvo spomenutoga,

¹⁸ Sukladno Pravilniku o znanstvenim i umjetničkim područjima, poljima i granama. https://narodne-novine.nn.hr/clanci/sluzbeni/2009_09_118_2929.html. Pristupljeno: 17. rujna 2022.

razlozi su i u samoj prirodi DH-a koja je prvenstveno orijentirana na konkretni istraživački problem, potom izradu i upotrebu alata specifičnih upravo problemu koji se u konkretnom slučaju nastoji riješiti. Dakle, određenu istraživačku metodu odabrat ćemo u konkretnom slučaju ili, pak, onda kada želimo raspraviti zašto su određene metode bolje u kontekstu određene tehnike – zašto primjerice deformacija primjenom Adobe Photoshopa može unaprijediti naše mišljenje o hermeneutici vizualnih umjetnosti?; kako algoritam izrađen u svrhu izdvajanja frekvencija riječi može unaprijediti naše mišljenje o odnosu roda i spola u Shakespeareovoj tragediji *Kralj Lear*?, itd. (Clement 2016, str. 159).

Ono što nam osobito zaokupljuje pažnju u kontekstu metodoloških pitanja, a što se samo po sebi nameće iz velikoga broja objavljenih studija, odnosni se na jedan drugi problem. Naime, većina se kritičara DH, i to bez obzira je li riječ o istraživačima u društvenom ili u humanističkom području znanosti ne osvrće toliko na problem metodologije, koliko na nedostatak jasnoga teorijskoga okvira. No, tu ćemo odmah zastati i jasno istaknuti kako se nikako se ne možemo složiti s mišljenjem prema kojem se ovdje radi o manje intelektualnoj disciplini koja pogoduje vremenu kojega karakterizira poremećen status znanja i mudrosti, kako se često u literaturi upozorava. Među takvim se kritičarima izdvaja, humanistima dobro poznati teoretičar književnosti Stanley Fish, koji je u dvama blogovima objavljenima u *New York Timesu* 2012. godine opisao DH kao gotovo evanđeosku disciplinu čiji pristaše vjeruju kako će zauzeti književnoteorijsko polje i za razliku od prijašnjega, štoviše pogrešnoga pristupa književnom tekstu riješiti krizu koja je nastupila u humanističkim znanostima, te da će

opremiti studente vještinama koje će im osigurati mjesto na tržištu rada. Nadalje, obrušava se na opsesiju digitalnih humanista u traženju obrazaca u podacima čije značenje uopće nije primjereno za interpretaciju te smatra kako i nije jasno što u njima istraživači traže. Drugim riječima, smatra kako se ne može govoriti o nekom značajnom istraživačkom usmjerenju iz razloga što digitalni humanisti u stvari rade previše, a misle premalo (Fish 2012 citirano u Warwick 2016, str. 560). Prema tome, jedna od temeljnih zamjerki jest nepostojanje jedinstvene teorije, ali i mišljenje kako se ovdje radi tek o nekakvoj reakciji na kritičku teoriju, ili, pak, teoriju uopće te se sugerira i podupire mišljenje prema kojem je vrijeme velikih teorija već daleko iza nas.

Naše je stajalište ipak nešto drugačije iz razloga što držimo kako bez tradicionalnih znanja stečenih u kontekstu klasičnoga humanističkoga obrazovanja nema i neće moći biti kvalitetnih istraživanja niti u digitalnoj humanistici. Slijedom navedenoga, nameće se pitanje čemu tolika zaokupljenost teorijom? Jer, činjenica jest da humanističko područje raspolaže bogatim teorijskim instrumentarijem kojega u pojedinim segmentima dijeli i s društvenim znanostima. Ovisno, dakle, o vrsti istraživanja DH u svoja istraživanja može implementirati niz teorijskih pravaca, npr. strukturalističku, psihoanalitičku, poststrukturalističku, kolonijalnu, postkolonijalnu, feminističku teoriju, teorije ideologije, sjećanja i pamćenja, teoriju posthumanizma, transhumanizma, ali i kognitivne studije, studije medija i novih medija. Međutim, kod spomena novih medija i uopće vizualne komunikacije koja sve više preuzima primat u brojnim disciplinama valja biti oprezan te upozoriti kako DH nikako nije nekakav ogranak studija novih

medija, medijskoga dizajna ili medijske umjetnosti. No, ona ulazi i u ovo područje što, između ostaloga, potvrđuju i brojne rasprave oko pokušaja objašnjenja kompleksnosti suvremenih kulturnih tijekova u ozračju digitalnih tehnologija. Tako je razumijevanje suvremene, digitalne kulture, ali i svakodnevne prakse koja pridonosi njezinoj popularizaciji gotovo nemoguće bez istodobnoga razumijevanja računalnoga kôda koji prožima sve aspekte naših života. Navedeno je u skladu s mišljenjem Mathewa Fullera koji ističe kako se cjelokupni intelektualni rad može danas okarakterizirati sintagmom *studiji softvera*, s obzirom da softver istodobno omogućuje funkcioniranje medija, ali i njegova konteksta (Fuller 2006 citirano u Berry 2012: 5).

Poteškoće s definiranjem DH-a, tu ćemo se složiti s Liu (2013), proizlaze iz one problematike koja je svojstvena samoj humanistici, a tiče se s jedne strane multidisciplinarnosti, a s druge strane one netom spomenute metodološke fluidnosti. Za humanistiku, digitalna humanistika premašuje, bez obzira što i uključuje, tek puku funkcionalnu ulogu nekakvoga instrumenta ili servisa, dodatnu disciplinu, ili neku lažno-političku ulogu koja bi joj se mogla nadjenuti kao novoj disciplini kojoj je cilj izazov ili, pak, reforma. Dakako, „proširivanje“ humanistike novom disciplinom, disciplinom koja u nazivu sadrži termin „digitalno“ moglo bi na prvi tren imati prizvuk kakvoga političkoga, tj. ideološkoga programa. No, takvo razumijevanje discipline bilo bi apsolutno površno te bi pokazalo potpuno nerazumijevanje čitavoga i iznimno važnoga povijesnoga slijeda njezina razvoja na kojega također i ovom knjigom nastojimo skrenuti pozornost. DH nam pokazuje kako humanistika slijedi promjene koje zahvaćaju

društvo u cjelini. Tehnologije su oduvijek bili pokretači značajnih promjena i iz temelja su mijenjale ekonomije, politike, znanost, obrazovanje. U kontekstu DH-a one su direktno uključene u kritičku analizu koja podrazumijeva algoritamski olakšano pretraživanje, dohvaćanje, obradu i prezentaciju informacija sugerirajući pritom potrebu za redefiniranjem klasičnih pristupa i usvajanjem novih znanja.

Ovu je digresiju bilo važno napraviti iz razloga što držimo kako ono što se podrazumijeva pod DH prvenstveno proizlazi iz humanistike, a rezultat je promjena koje su tehnologije donijele na širem društvenom i kulturnom planu uopće. Stoga nije pretjerano kazati kako DH posjeduje simboličku ulogu jer na neki način osigurava budućnost humanistike koja će se htjeti (i morati!) uključiti u vrijednosti suvremenoga društva, ne gubeći istodobno vlastitu srž i temeljno znanje svih disciplina koje pripadaju ovom znanstvenom području. Stoga je primarni zadatak DH-a usmjeren spretnoj artikulaciji načina na koji će se određene metodološke perspektive situirati u humanistički epistemološki okvir. Nove metode koje se pojavljuju u kontekstu DH-a, kao što su statističke analize, vizualizacija, etnografija, itd. naprosto ne smiju egzistirati u vakuumu. Moguće je da upravo u interakciji sa studijima novih medija imamo jedinstvenu priliku postavljati nova, drugačija istraživačka pitanja te ih istražiti i prezentirati na novi i drugačiji način. Digitalna humanistika, dakle, podrazumijeva znanstvenika koji razmišlja o tehnologiji i involviran je u procese njezina korištenja, ali i stvaranja i to kako u procesu poučavanja, tako i u provedbi istraživanja. Sukladno navedenom, složiti ćemo se s mišlju Wymer (2021) koja smatra kako DH valja držati disciplinom

koja omogućuje okupljanje koncepata i prakse uporabe novih tehnologija s ciljem transformacije studija humanistike. U takvom ozračju istraživačko pitanje postaje okosnica za izgradnju projekta, a digitalni alati sredstva koja su na usluzi tijekom provedbe istraživanja. Ova propaganda korištenja novih tehnologija kojoj smo svakodnevno izloženi ne smije nas uvesti u stupicu robovanja alatima, što drugim riječima znači da ne smijemo istraživačku ideju kreirati ovisni o alatima koji su nam u određenom trenutku dostupni.

Institucionalizacija digitalne humanistike

U prethodnom poglavlju istaknuli smo kako je oko HR okupljen čitav niz publikacija, centara i drugih institucija u kontekstu kojih se disciplina nastojala etablirati. Gotovo identičan put prati i DH pa tako kao jednu od temeljnih publikacija u području svakako valja istaknuti Blackwellov (2005) *Companion to Digital Humanities* iz 2005. godine. Objavljen je, doduše, čitav niz knjiga na ovu temu, a među izdavačima osobito se, barem početka, ističe University of Illinois Press. Godine 2012. John Bradley osigurao je važan uvid u novoosnovane centre, među kojima je izdvojio Odsjek za digitalnu humanistiku na King's College London kao jedinicu koja potiče kolaborativna istraživanja na kojima računalni stručnjaci rade zajedno s humanističkim znanstvenicima. U kontekstu izdanja usmjerenih usvajanju tehnika i praksi koji se koriste u analizi podataka, a pisana na način da se što jednostavnije prikaže moguća upotreba programskog jezika/alata Python, svakako valja izdvojiti knjigu *Humanities Data Analysis*:

Case Studies with Python autora Karsdorpa, Kestemonta, Riddela iz 2021. godine.

Među časopisima ističu se *Digital Humanities Quarterly*, te *Digital Studies/Le champ numérique*, kojega sponzorira Canadian Society for Digital Humanities. Sveučilište Victoria, nadalje, svake godine organizira ljetnu školu s ciljem obučavanja novih istraživača. Postoji više od stotinu centara i instituta diljem svijeta, a tri su recentna izvještaja koja iznose detaljni administrativni okvir razvoja discipline. Prva dva orijentirana su prvenstveno na prostor SAD-a, a riječ je o onima autorice Diane M. Zorich (2008) izrađen za *Council on Library and Information Resources*, te autorica Nancy L. Maron i Sarah Pickle (2014) *Sustaining Digital Humanities: Host Institution Support Beyond the Start-Up Phase*. Treći je međunarodnoga karaktera i iznijet u seriji izvrsnih članaka autora Patricka Svenssona iz 2009., 2010., 2011. i 2012. godine (citirano u Prescott, 2016). Jednako tako, objavljeni su manifesti digitalne humanistike, a godišnje se diljem svijeta organizira niz radionica, edukacija, simpozija i okruglih stolova. Rasprave se vode i na blogovima, na društvenim mrežama poput Facebooka i Twittera (Kirschenbaum 2012, str. 196). Popis, nadalje, aktualnih centara u području dostupan je na Internet stranicama *centerNet* (*An international networks of digital humanities centers*; <https://dhcenternet.org/centers>), međunarodne mreže osnovane 2007. godine formirane s ciljem povezivanja centara diljem svijeta, ali i s ciljem unaprjeđenja istraživanja u području digitalne humanistike. Kao partneri pojavljuju se *Alliance of Digital Humanities Organizers* (ADHO), *Coalition of Humanities and Arts Infrastructure and Networks* (CHAIN), *Consortium of Humanities Centres and*

Institutes (CHCI), *Common Language Resources and Technology Infrastructure* (CLARIN), te *Digital Reserach Infrastructure for the Arts and Humanities* (DARIAH). Treba istaknuti i međunarodnu mrežu digitalnih humanista Global Outlook::Digital Humanities (GO::DH, <http://www.globaloutlookdh.org/>), koja promovira komunikaciju i suradnju među istraživačima i studentima iz područja digitalne umjetnosti, humanistike i kulturne baštine u visoko, srednje i nisko razvijenim ekonomijama. Sudionici ove mreže uključuju se sa svih strana svijeta s ciljem unaprjeđenja digitalno usmjerenoga rada u području umjetnosti, humanističkoga i baštinskoga sektora. Temeljne aktivnosti GO::DH-a su: povećanje vidljivosti digitalnoga rada pripadnika spomenutih sektora u cijelom svijetu; jačanje zajednice i jačanje suradnje među regijama i različitim ekonomijama; koordinacija istraživanja i podrška u upotrebi tehnologije u navedenim sektorima diljem svijeta; diseminacija i prijevodi istraživanja objavljeni u časopisu *Digital Studies/Le champ numérique*; zastupanje globalne perspektive DH-a u nacionalnom i međunarodnom kontekstu.

Willard McCarty i Matthew Kirschenbaum izradili su 2003. godine listu svih odsjeka, centara, instituta, časopisa, elektroničkih izvora i drugih institucionalnih formi usmjerenih na istraživanja u području digitalne humanistike. Ova je baza dostupna i u internetskoj verziji na stranicama *Eruopean Association for Digital Humanities* te se osvježuje na godišnjoj razini (<https://eadh.org/publications/institutional-models-humanities-computing>). Riječ je o zaista impresivnom popisu kojim se asocira legitimitet područja vrijednoga dubljeg znanstvenoga promišljanja i koje zasigurno može pridonijeti revitalizaciji humanističkih znanosti

u modernom, ali i tehnološki orijentiranom svijetu. Upravo su centri jedni od glavnih pokretača razvoja digitalne humanistike tijekom posljednjih 25 godina, te će bez sumnje igrati značajnu ulogu i za budućnost njezina razvoja. U središtu njihova rada jest organizacija i stvaranje digitalnih izvora, razvoj digitalnih alata, korištenje digitalnih kolekcija i analitičkih alata u svrhu razvoja novih intelektualnih produkata, organizacija predavanja i seminara, organizacija radionica, itd. Najznačajnija tijela usmjerena financiranju istraživanja i ohrabriranju sveučilišta u pokretanju sličnih centara jesu National Endowment for the Humanities (NEH) i Mellon Foundation (Prescott 2016, str. 465). Nekolicina je značajnih inicijativa na prostoru Europske Unije, kao što su primjerice NeDiMAH (the Network for Digital Methods in the Arts and Humanities; www.nedimah.eu), koji prati upotrebu digitalnih istraživanja diljem Europe. Valja, nadalje, izdvojiti i već spomenuti DARIAH (www.dariah.eu), koji nastoji izgraditi integrativnu kooperativnu mrežu ljudi, informacija i alata kako bi se olakšao dugoročni pristup alatima i istraživačkim informacijama diljem Europe. U ovom kontekstu valja izdvojiti i združenu inicijativu 27 organizacija za financiranje istraživanja iz 24 zemalja, CHANSE (Collaboration of Humanities and Social Sciences in Europe; <https://chanse.org/>). Jedan od osnovnih ciljeva ove inicijative jest objava natječaja za međunarodne istraživačke projekte pod nazivom Transformation: Social and cultural dynamics in the digital age. CHANSE program potencira suradnju između znanstvenika, različitih poslodavaca i ostalih grupacija, a za područje digitalne humanistike bit će zanimljivo vidjeti rezultate istraživanja projekata koji su dobili financiranje na natječaju iz

2021. godine Transformations: Social and Cultural Dynamics in the Digital Age¹⁹.

Digitalna humanistika u kontekstu visokoga obrazovanja

Nastavni planovi i programi općega obrazovanja, a kojega su humanističke discipline sastavni dio nisu pratili promjene koje su nove tehnologije sustavno unosile na tržište rada i društvo u cjelini. Većina sveučilišnih nastavnih planova i programa nije prilagođena stvarnosti u kojoj žive upravo studenti koji vode život bitno drugačiji, digitalniji i umreženiji, nego što je to bio slučaj u vremenu u kojem su ti isti programi dizajnirani. Većina sveučilišta, a nije to samo hrvatski specifikum, nije uspjela prenijeti studentima smisao studiranja humanističkih znanosti u novom, digitalnom okruženju pa stoga i nije čudno što se veliki broj studenata okreće nehumanističkim smjerovima, odnosno studijskim programima koji im garantiraju mjesto na tržištu rada. Stoga, smisljeno i organizirano uvođenje digitalnih tehnologija u sustav visokoga obrazovanja, tj. u sveučilišne studijske programe može predstavljati početak onoga što Kuhn (2013) naziva revolucijom u znanosti, a odnosi se na pomak u ontologiji pozitivizma i usmjeravanju prema stvaranju novoga ozračja, odnosno nove normalne znanosti. Navedeno znači kako će, ontološki promatrano, različite discipline posjedovati zajednički temelj izgrađen u prvom redu na informacijsko-komunikacijskim tehnologijama, a što će imati značajne konzekvence u smislu unificiranja znanja

¹⁹ <https://chance.org/call-for-proposals/> Pristupljeno 14. rujna 2022.

i uopće u koncipiranju ideje o suvremenom sveučilištu. U takvom okruženju računalne znanosti imaju potencijala preuzeti fundamentalnu ulogu u razvoju, ali i daljnjem usmjeravanju svih ostalih znanstvenih disciplina. Prvenstvo kojega nove tehnologije preuzimaju u akademskom životu, ali i društvu u cjelini ne treba shvatiti kao strogi tehnocentrizam kojemu je cilj do temelja uništiti vrijednosti humanizma. Upravo suprotno. Ulogu računala valja domesticirati, shvatiti je na onaj isti način na koji smo u ne tako davnoj prošlosti u „miru živjeli“ i služili se papirom i olovkom. U kolaboraciji s humanističkim znanostima, računalne tehnologije mogu doprinijeti unaprjeđenju moći razmišljanja, mogu otpustiti kočnice imaginacije, ali i omogućiti revitalizaciju ideje o političkoj jednakosti, a što samo govori u prilog činjenici kako je uloga humanističkih disciplina baš danas osobito važna.

Računalni pristupi olakšavaju međuprožimanje različitih disciplina, a što vodi stvaranju postdisciplinarnoga sveučilišta, što dakako može uznemiriti tradicionalni pristup u formiranju obrazovnih politika i organizaciji sveučilišta. Nove su tehnologije suviše involvirane u sve segmente društvenoga života i bilo bi naivno misliti kako taj utjecaj u narednim godinama neće biti još snažniji²⁰, a što

²⁰ Ono što je u kontekstu obrazovanja i istraživanja zanimljivo jest činjenica da je upravo softver taj koji omogućuje nove načine čitanja i pisanja, a kao jedan od reprezentativnih primjera u tom smislu izdvaja se mišljenje Tanye Clement vezano uz tzv. udaljeno čitanje djela Gertrude Stein, *Stvaranje Amerikana* (*The Making Americans*) iz 1925. godine. Naime, mnogi su spočitavali kako je riječ o izuzetno teško čitljivom romanu, svojevrsnom gramatičkom eksperimentu na gotovo 900 stranica, s 3147 paragrafa i s oko 5000 jedin-stvenih riječi. No, upravo je metoda tzv. rudarenja teksta (engl. *text mining*), korištenje statističkih metoda i vizualizacije rezultata analize omogućila da se jedan ovako opsežan i složen tekst predstavi na drugačiji i organiziran način. Rezultati istraživanja pokazali su se posve suprotnima od onoga što se

dodatno pokazuje podatak kako je u razdoblju od 2010. do 2016. godine osobito porastao interes za zapošljavanje upravo digitalnih humanista na brojnim istraživačkim sveučilištima, npr. na Sveučilištu Iowa, na Državnom sveučilištu Georgia, Sveučilištu Maryland i Sveučilištu Wisconsin. Iako je rad u digitalnoj humanističkoj znanosti mnogo pridonio na usvajanju značaja informacijsko-komunikacijskih tehnologija za sveučilišnu zajednicu općenito, one jednako tako imaju potencijala preoblikovati ulogu humanističkih znanosti na sveučilištima budućnosti (Waltzer 2016, str. 336).

U prethodnom poglavlju istaknuli smo kako kraj devedesetih godina prošloga stoljeća karakterizira uvođenje područja humanističkoga računalstva u sustav visokoga obrazovanja. Ova će se tendencija, zahvaljujući razvoju tehnologija i sve većoj dostupnosti digitaliziranih i digitalnih izvora koji značajno olakšavaju učenje i poučavanje nastaviti i tijekom 21. stoljeća. Studijski programi iz digitalne humanistike organiziraju se najčešće na diplomskoj razini te se uglavnom koncentriraju na istraživanje jezika, književnosti, kulture i vizualnih medija. U tom kontekstu spominju se u europ-

romanu prigovaralo te se pokazalo kako je riječ o iznimno organiziranom, sistematičnom tekstu. Istraživanje je u konačnici pomoglo u približavanju djela studentima humanistike te je znatno olakšalo njegovo čitanje i daljnja. Inače, Berry (2011) osobito pažnju posvećuje sistematizaciji velikih količina podataka, ali i njihovoj vizualizaciji te smatra kako će se u različitim strukama i znanostima uvesti metoda prevođenja podataka i informacija u upotrebljive računalne forme s ciljem njihova boljega razumijevanja. Govori, također, i o tzv. računalnoj formi novinarstva, utemeljenoj na kreiranju novinarskih članaka koji kombiniraju tekst, sliku, video, računalne aplikacije i interaktivnost. Riječ je o tzv. formi umreženoga novinarstva koja uključuje nelinearnost i višedimenzionalne procese stvaranja. Dakako, ova forma novinarstva u međunarodnim okvirima više nije novost, no činjenica jest da i ona zahtjeva reorganizaciju klasičnih studijskih programa novinarstva, posebice u nacionalnim okvirima.

skom sustavu visokoga obrazovanja, primjerice Master in Linguistic Diversity and Digital Humanities na Sveučilištu Helsinki, Master of Digital Humanities na Sveučilištu Barcelona, MA Media Studies: Digital Cultures na nizozemskom Maastricht sveučilištu, itd. Jedno od najutjecajnijih i najstarijih središta u području digitalne humanistike zasigurno jest King's College iz Londona, a Odsjek za digitalnu humanistiku posjeduje osebujnu tradiciju koja seže još u 1992. godinu kada je prvotno osnovan Centar za računalstvo u humanističkim znanostima (Centre for Computing in the Humanities). Odsjek za digitalnu humanistiku svjetski je poznati istraživački centar koji se orijentira prema istraživanjima upotrebe naprednih tehnologija u humanistici. Odsjek nudi preddiplomski studijski program Digital Culture, diplomске studije Big Data in Culture and Society; Digital Culture and Society, Digital Asset and Media Management, ali i doktorski studij Digital Humanities²¹.

Što se tiče hrvatskoga sustava visokoga obrazovanja moramo istaknuti kako se nastojanja oko uvođenja informacijsko-komunikacijskih tehnologija u istraživačke projekte i studijske programe uglavnom povezuju s Odsjekom za informacijske i komunikacijske znanosti i Odsjekom za lingvistiku Filozofskoga fakulteta Sveučilišta u Zagrebu. Unatoč nastojanjima oko jačanja digitalne humanistike u nacionalnom istraživačkom prostoru koja dolaze od znanstvenika s drugih Filozofskih fakulteta u zemlji, Odjela za informacijske znanosti Sveučilišta u Zadru te s Instituta Ruđer Bošković, razvidno je kako upravo gore spomenutim Odsjecima valja priznati prvenstvo u inicijativi etabliranja digitalne humanistike u nacionalnom znanstveno-istraživačkom prostoru. Valja na ovom mjestu istaknuti

²¹ Izvor: <https://www.kcl.ac.uk/ddh/about/about> Pristupljeno: 4. listopada 2022.

kako je 2020. godine na Sveučilištu Sjever pokrenut Centar za razvoj digitalnih kompetencija i tehnologija e-učenja kojemu je, između ostaloga, cilj pokretanje edukacija i programa cjeloživotnoga obrazovanja i u području digitalne humanistike. Iz navedenoga je vidljivo kako, unatoč činjenici što formalni okvir u smislu različitih strategija, propisa i dokumenata ipak postoji, kod nas još uvijek nije zaživjela jedinstvena, snažna i jasna znanstveno-istraživačka i obrazovna strategija koja bi se fokusirala na aktivno i smisleno uvođenje digitalnih tehnologija na svim obrazovnim razinama. Međutim, svjedočimo trenutku u kojem je broj objavljenih znanstvenih članka, obranjenih diplomskih i doktorskih radova, znanstveno-istraživačkih projekata ipak u porastu te držimo kako je sazrelo vrijeme da se i u nacionalnom kontekstu počne jasno i organizirano okupljati zajednica digitalnih humanista.

Znanstveno-istraživački smjerovi digitalne humanistike

Godine 1902. Max Weber istaknuo je kako nova „znanost“ nastaje u trenutku u kojem postaje evidentno kako se novi problem nastoji razriješiti novom metodom. Na temeljima upravo navedene misli Franco Moretti osmislio je novu metodu u proučavanju književnosti, metodu tzv. udaljenoga čitanja (engl. *distant reading*). Moretti (2013), naime, smatra kako svjetska književnost više ne predstavlja objekt istraživanja, nego prije svega problem i to problem koji vapi za novim kritičkim metodama. Jer, novu metodu nije moguće osmisliti povećanjem primjerice broja pročitanih književnih djela. Na taj način ne nastaju niti nove teorije, već im

je neophodan pokretač i to u onaj obliku hipoteza. Prema tome, hipoteze su pokretač analize iza koje slijedi sinteza da bi na koncu došli do faze oblikovanja teorije.

Unatoč nastojanjima da se novim metodama kojima se od nove kritike do dekonstrukcije nastojalo osvježiti područje teorije i povijesti književnosti, klasično ili pomno čitanje (engl. *close reading*) za Morettija je problematično iz razloga što se usredotočuje na ekstremno mali kanon. Metoda, naime, pomnoga čitanja ograničava nas ne samo na čitanje kanonskih djela svjetske književnosti, već nas istodobno sputava u istraživanju svih onih djela koja u taj kanon nisu niti ušla²². Takva ograničenja moguće je prevladati metodom udaljenoga čitanja koju Moretti drži stanjem znanja, metodom koja omogućuju fokusiranje na jedinice koje su znatno manje ili znatno veće od samoga teksta, kao što su npr. teme, tropi, žanrovi, sustavi. Cilj je, dakle, primjenom metode udaljenoga čitanja, premda postoje primjeri njezine primjene na samo jednom književnom djelu, obuhvatiti veliki korpus tekstova te uporabom računalnih alata, kvantitativnom analizom i vizualizacijom dobivenih rezultata istraživanja predstaviti obrasce i trendove svojstvene nekom književnom razdoblju, autoru ili, pak, ukazati na žanrovske, tematske, stilske specifičnosti korpusa koje u kontekstu pomnoga čitanja nije moguće detektirati.

²² Prema Craneu (2008) gornja granica koju čovjek može za života pročitati i to pod pretpostavkom da od petnaeste do osamdeset pete godine života čita knjigu dnevno, jest dvadeset i pet tisuća knjiga. Nasuprot tome, digitalni/digitalizirani tekstovi koji se mogu pretraživati, analizirati i korelirati pomoću strojnih algoritama broje se u stotinama tisuća, a s Googleovom tražilicom knjiga taj se broj penje na milijun i više (Crane 2008 citirano u Hayles 2012, str. 27).

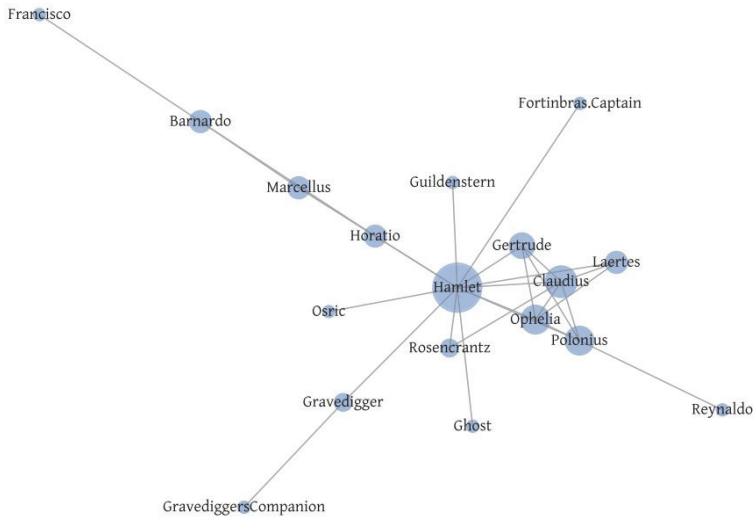
Ove i slične računalne i statističke metode naišle su, već smo upozorili, na brojne kritike tradicionalnih humanističkih znanstvenika pa nije za čuditi što kao jedno od središnjih pitanja oni ističu pitanje uopće smislenosti takvih istraživanja. Smisao se određuje kao metavrijednost i metaproblem DH-a, što dodatno podcrtava i projekt Ryana Heusera i Long Le-Khaca iz 2012. godine naslovljen *A Quantitative Literary History of 2,958 Nineteenth-Century British Novels: The Semantic Cohort Method*. Klasična studija iz 1958. godine *Kultura i društvo: 1780.-1950. (Culture and Society: 1780-1950)* u kojoj autor Raymond Williams istražuje načine na koje promjene u diskursu otkrivaju šire povijesne i sociokulturne promjene, glavni je poticaj Heuserova i Le-Khacova istraživanja (Heuser i Le-Khac, 2012). Naravno, Williamsov pokušaj analize cjelokupnoga društvenoga diskursa, koliko god nam djelovao zadivljujuće, bio je prije svega pretenciozan s obzirom da su mu nedostajali alati i korpusi koji su sada ipak dostupni znanstvenicima digitalne humanistike. No, potaknuti radnom metodom znanosti u kojoj su zaključci koji se donose nakon provedenoga eksperimenta dio kontinuiranoga procesa istraživanja, a primjenom računalne metode na vrlo velikom korpusu tekstova – autori su nastojali analizirati duboke promjene u jeziku i kulturi i ponuditi drugačiji pogled na povijest književnosti i društva²³. U svakom eksperimentu, kako ističu, put od podatka do zaključka iznimno je zamršen i karakterizira ga bojazan od mogućih pogrešnih interpretacija. No,

²³ Projekt je podijeljen u četiri faze: faza 1 – „početne riječi“ i početni problemi; faza 2 – korelator; faza 3 – semantička taksonomija i kategorizacija; faza 4 – statističko filtriranje. Fokusirali su se na objekt semantičkoga polja te su nastojali dokazati kako bi se povijest književnosti mogla predstaviti upravo u kontekstu ove kategorije (detaljnije u Heuser i Le-Khac 2012, str. 3-7).

ono što je posebno izazovno u DH odnosi se u principu na smisao istraživanja primjerice učestalosti upotrebe neke riječi na velikom korpusu književnih djela, a na što je, između ostalih, 2008. godine u radu *Modeling: A Study in Words and Meanings* upozorio i Willard McCarty (McCarty 2005). Upravo u tom nastojanju da se u tom makroskopskom zahvatu nad književnim korpusom kvantitativni podaci dodatno objasne i interpretiraju na način da u ozračju svojstvenom humanistici doista odišu smislom, i valja tražiti iskorak u odnosu na slična istraživanja koja su se u sklopu humanističkoga računalstva provodila desetljećima prije. Slijedom navedenoga zaključujemo kako su Heuser i Le-Khac osobiti značaj i pridali izbjegavanju različitih metodoloških zamki u koje su u istraživanju ovoga tipa vrlo lako mogli upasti. Nastojali su biti što rigorozniji u svojim tumačenjima, no istodobno su ukazivali i na potrebu ustrajnosti digitalne humanistike za postavljanjem velikih pitanja i iznošenjem velikih tvrdnji. Jednako tako, ukazali su na važnost usavršavanja metodologije i originalnosti argumenata koji imaju snage unaprijediti koncepte i teorije pa u tom kontekstu pozornost posvećuju upravo humanističkim načinima argumentacije koji se nerijetko temelje na snažnim idejama koje bez obzira što nisu do kraja sigurne i konačne, posjeduju moć potaknuti znanstvenike na daljnje proučavanje i preispitivanje donesenih zaključaka.

Netom spomenutoj tendenciji za konstantnim napredovanjem u metodologiji valja pridružiti i već spomenuto izdanje autora Karsdorpa, Kestemonta i Ridella iz 2021., a koji osobitu pažnju posvećuju kvantitativnim analizama podataka u humanistici s posebnim osvrtom na različite mogućnosti koje, a sukladno specifičnostima pojedinih istraživanja nudi programski

jezik/alat Python. Tako je knjiga *Humanities Data Analysis: Case Studies with Python* podijeljena u dva dijela (Karsdorp, Kestemont i Ridell 2021). U prvom dijelu posebna pažnja posvećena je tehnikama prikupljanja, čišćenja, predstavljanja i pretvorbi tekstualnih u tablične podatke. S ciljem predstavljanja potpune analize podataka, u prvom je poglavlju iznijeta istraživačka analiza podataka na primjeru povijesti kuharica. Ukratko, prikazani su svi koraci koji uključuju potpunu analizu podataka, kao i načine na koje Python olakšava primjenu ovih koraka. Nakon što su skicirani glavni elementi kvantitativne analize, u drugom poglavlju opisane su tehnike prikupljanja i razmjene podataka. Izgrađeno oko studije slučaja izdvajanja i vizualizacije društvene mreže likova u Shakespeareovu Hamletu, ovo poglavlje pruža detaljan uvid u različite modele razmjene podataka kao i mogućnosti korištenja Pythona za učinkovito prikupljanje, čitanje i pohranjivanje različitih formata, npr. CSV, JSON, PDF i XML. Nadalje, treće se poglavlje nadovezuje na ovo prethodno te se orijentira na mogućnosti predstavljanja teksta za daljnju analizu. Jedna od takvih mogućnosti jest i usporedna analiza dokumenata, a alat koji se u tom smislu pojavljuje kao izuzetno moćno sredstvo reprezentacije jest Vector Space Model (VSM). U svrhu ilustracije svih potencijala i prednosti VSM-a, u poglavlju se analizira korpus klasične francuske drame te se pokazuje kako se ovakve analize mogu koristiti za kvantitativnu procjenu sličnosti ili različitosti između tekstova i žanrova, tj. podžanrova.



SLIKA 2-1: Mreža karaktera u tragediji Hamlet²⁴.

IZVOR: Karsdorp, Kestemont i Ridell 2021, str. 33.


Drugi dio knjige pruža detaljniji uvid u primjere analize podataka uz pomoć Pythona pa se tako u petom poglavlju, a koje se nastavlja na drugo i četvrto i u kojem je predstavljena biblioteka Pandas²⁵, donosi statistički opis rezultata ankete o čitanju književnih djela i razumijevanju klasične glazbe. Središnja tema sljedećega poglavlja jesu Federalistički spisi u kojem se nastoji pokazati kako teorija vjerojatnosti i Bayesov zaključak mogu doprinijeti razrješavanju još uvijek intrigantnoga slučaja oko utvrđivanja autorstva. U sedmom poglavlju raspravlja se o nekoliko temeljnih tehnika za kreiranje geografskih karata uz

²⁴ Primjer mreže likova izrađene putem Pythona. Uvjet uvrštavanja likova u mrežu jest uključenost u komunikacijski proces barem deset puta u tragediji *Hamlet* (Karsdorp, Kestemont i Ridell 2021, str. 33).

²⁵ Pandas je jedna od popularnijih Pythonovih biblioteka za tabličnu manipulaciju i analizu podataka. Omogućuje učinkovitu, brzu i jednostavnu analizu podataka (Karsdorp, Kestemont i Ridell 2021, str. 14).

pomoć Pythona, te se opisuje skup podataka koji opisuju važne bitke koje su se vodile tijekom Američkoga građanskog rata. U osmom poglavlju fokus je ponovno na tehnici utvrđivanja autorstva te je predstavljen niz značajnih metoda i tehnika u stilometriji, npr. *Burrow's Delta*, *Agglomerative Hierarchical Clustering*, *Principal Component Analysis*. U devetom, završnom poglavlju nastoje se povezati prethodna poglavlja te se čitatelji, a posebice istraživači i studenti u području humanističkih znanosti pozivaju na stjecanje računalnih znanja i vještina, te potom i na korištenje predstavljenih tehnika i metoda.

Hildegard od Bingena jedna je od najutjecajnijih srednjovjekovnih autorica iz 12. stoljeća, a njezin je epistolarni korpus predmetom brojnih studija. Kestemon, Moens i Deploige 2015. godine proveli su stilometrijsku analizu s ciljem utvrđivanja autorstva u određenom broju pisama. U tu svrhu provedena je usporedna analiza Hildegardinih pisama s dobro poznatim opusom Bernarda od Clairvauxa i Guilberta od Gamblouxa. Doljepredstavljeni dijagram izveden je upravo iz spomenute studije, te predstavlja vizualizaciju razlika u stilu između triju opusa (Karsdorp, Kestemont i Ridell 2021, str. 248).



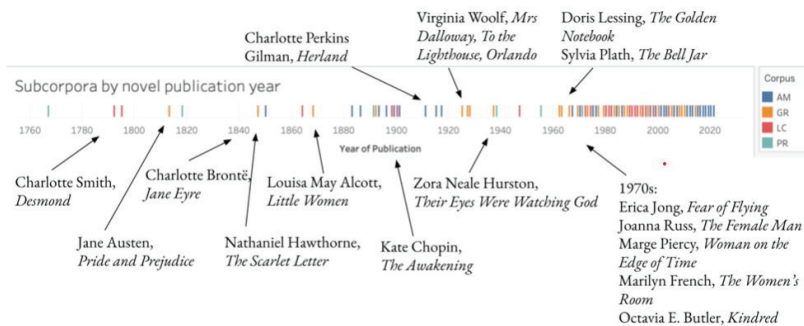
SLIKA 2-2: Dijagram analize glavnih komponenti koji suprotstavlja 10 000 lematiziranih uzoraka riječi iz triju opusa – Bernarda iz Clairvauxa, Hildegarde iz Bingena i Guilberta iz Gemblouxa. Izvor: Karsdorp, Kestemont i Ridell 2021, str. 248.

Cilj nam je, naime, ovim potpoglavljem izdvojiti tek nekolicinu istraživanja i izdanja za koje držimo da će čitateljima olakšati uvid u disciplinu i omogućiti stvaranje dojam o širini i složenosti smjerova svojstvenih digitalnoj humanistici. Ne pretendiramo predstavljanju sveobuhvatnoga pregleda projekata i radova, već se — s obzirom na temeljna znanstveno-istraživačka usmjerenja autora, a koja osim područja matematike, informatike, računalstva, fonetike, uključuju i filološke discipline—usredotočujemo prvenstveno na tekst te

općenito na pojam kulture. Brojna ćemo istraživanja, radove i projekte koji pripadaju drugim područjima stoga ostaviti po strani svjesni kako su jednako tako važna ne samo za razvoj, nego i za potpuno razumijevanje digitalne humanistike.

Sljedeći upravo spomenutu orijentaciju čini nam se zanimljivim u ovom kontekstu izdvojiti znanstveni časopis u otvorenom pristupu *Journal of Cultural Analytics* (<https://culturalanalytics.org/>) pokrenut 2016. godine u kojem su tijekom prve tri godine izlaženja analize književnih tekstova u odnosu na ostala umjetnička i kulturna područja bile evidentno zastupljenije. Tako se objavljeni radovi uglavnom orijentiraju na devetnaestostoljetne i suvremene romane u engleskoj književnosti; ilustrirane novinske tekstove objavljujane tijekom 19. st.; američke televizijske serije, itd. (Manovich 2020. str. 8). Iako se tijekom posljednje dvije, tri godine objavljuju i rasprave i eseji o statusu kulture i humanistike uopće u kontekstu podatkovnih znanosti, kao i analize radijskih emisije te različitih trendova na društvenim mrežama, ipak je i dalje razvidan prevladavajući trend računalnoga pristupa u rješavanju različitih problema na primjeru različitih književnih korpusa. Zanimljivo je u tom kontekstu spomenuti kako ovi noviji radovi pokazuju tendenciju situiranja velike količine kvantitativnih podataka u širi kulturološki i književnoteorijski okvir te na taj način govore u prilog onoj našoj prethodno iznesenoj tvrdnji o važnosti „tradicionalnoga“ teorijskoga instrumentarija za digitalnu humanistiku. Jedno od takvih istraživanja jest i ono autorica Mendelman i Mukamal (2021) naslovljeno *The Generative Dissensus of Reading the Feminist Novel, 1995-2020: A Computational Analysis of Interpretive*

Communities. Članak istražuje dinamiku feminističkoga romana u četiri izdavačka konteksta: suvremenoj anglofonoj književnoj kritici, prestižnim recenziranim publikacijama, marketinškim materijalima i internetskim recenzijama knjiga koje objavljuju čitatelji na društvenim mrežama. Istražuje načine na koje se ove interpretativne zajednice približavaju i razilaze u svojim procjenama feminističke fikcije tijekom dvadesetpetogodišnjega razdoblja. Autorice prate ambivalentne sudbine feminističkoga romana u i preko spomenute četiri domene. Kvantitativne rezultate sintetiziraju s kvalitativnom pažnjom za provokativne primjere iz odabranoga korpusa smatrajući pritom kako književni znanstvenici mogu razviti snažnija razumijevanja o tome što feminizam i feministička fikcija znače suvremenim čitateljima. Predstavljena analiza pokazuje kako čitanje feminističkoga romana može pridonijeti produblivanju feminističkoga znanja, ali i konstruiranju feminističkih sustava vrijednosti.



SLIKA 2-3: Potkorpus prema godini izdanja
IZVOR: Mendelman, Mukamal 2021:45.

Autorice nastoje ukazati na činjenicu kako feministička fikcija posjeduje dugu tradiciju, a što i vizualno pokazuju ovim izdvojenim prikazom potkorpusa prema godini izdanja. Nakon

1920-ih godina, a osobito nakon 1960-ih godina evidentan je veliki broj romana pa je ova vremenska dinamika usklađena s ukupnim povećanjem i specifičnim dokumentiranim trendovima u izdavaštvu tijekom 20. i početkom 21. st. (isto., str. 45).


Nekolicinom gore izdvojenih primjera nastojali smo pokazati kako različite književne analize povezuje, u posljednjih nekoliko godina osobito popularan trend vizualizacije informacija. Navedeno je u skladu s onim općenitim značajem koji vizualni element ima u današnjoj znanosti i društvu općenito. Dominacija vizualnoga priziva, naime, potrebu za redefinicijom tradicionalnih pojmova koji posjeduju dugu humanističku tradiciju (npr. narativ, estetika), ali i poziva na posve drugačije pristupe u istraživanju ne samo pojedinačnih artefakata, nego i na pomake u shvaćanju uloge i značaja koje primjerice i baštinske institucije imaju u suvremenom svijetu. Istaknuto posebno apostrofira Lev Manovich (Manovich 2020) u svojoj knjizi *Kulturna analitika (Cultural Analytics)* iz 2020. godine u kojoj zastupa stajalište prema kojem je, osim što je primarno vizualna, suvremena kultura skup podataka koje valja istraživati metodama podatkovnih znanosti. Manovich se interesira velikom količinom vizualnih kulturnih podataka koje analizira različitim računalnim alatima kako bi rezultate istraživanja ponovno uz pomoć računalnih alata predstavio na vizualno dojmljiv način. Svojoj metodi nadjeva naziv kulturna analitika²⁶, no poticaj, i to unatoč njezinoj ipak primarnoj usredotočenosti na tekst, pronalazi upravo u digitalnoj humanistici. Za razliku, dakle, od povijesnoga teksta koji je najčešći objekt istraživanja u

²⁶ Godine 2007. Manovich pokreće laboratorij pod nazivom *Software Studies Initiative* (<http://lab.softwarestudies.com/2016/11/please-use-our-new-wesbite.html>), te kreira termin *kulturna analitika*.

DH, Manovich se orijentira na suvremenu digitalnu kulturu te primjenom računalne analize nastoji, na primjeru različitih izvora, detektirati obrasce i trendove svojstvene suvremenoj kulturi i umjetnosti. Manovichev radu svojstvena su dva cilja, s jedne strane korištenjem različitih računalnih alata i vizualizacijom podataka nastoji istražiti i analizirati različite oblike suvremenih medija i načina na koje korisnici ulaze s njima u interakciju. S druge strane, nastoji ponuditi teorijski okvir u kontekstu kojega pokušava detektirati načine na koje korištenje novih metoda i velikih skupova podataka dovodi u pitanje postojeće moderne ideje o kulturi. Glavni poticaj vlastitim istraživanjima pronalazi u želji da koristeći računalne metode, uključujući vizualizaciju podataka, medijski dizajn, statistiku i strojno učenje istraži suvremene kulturne trendove i omogući da se što veći broj ljudi upozna s onim što se svakodnevno u području kulture i umjetnosti događa diljem svijeta. Smatra kako koncept kojega nudi ne bi trebao biti samo teorijski, već i kvalitativan, usmjeren mjerenju trendova digitalne kulture i usporedbi stilova, ukusa, imaginacije, kulturnoga ponašanja i to u različitim geografskim područjima. Navedeno znači da je u pojedinim slučajevima potrebno posegnuti i za kvantificiranjem (osobito u slučajevima analize stila), međutim upozorava na limite koje puka kvantifikacija donosi te poziva na osjetljivost za različite dimenzije i aspekte kulture koji nisu tako lako mjerljivi.

No, činjenica jest kako numerička reprezentacija, analiza i vizualizacija podataka u nastojanju da se opišu kulturni artefakti, iskustva i dinamika suvremenoga kulturnoga života, zasigurno nude novi, drugačiji jezik. Korištenjem brojeva i vizualizacijom

podataka možemo lakše detektirati one jedva vidljive razlike između velike količine artefakata i grupe artefakata. U tom smislu, podatkovna znanost sa svojim različitim metodama (analiza klastera, mrežna analiza, itd.), postaje i te kako relevantna. Brojevi i vizualizacija podataka tako nude jedan drugačiji jezik kojim je moguće prikazati postupne i kontinuirane vremenske promjene te opisati specifičnosti kulturnih procesa. Upravo, stoga, istraživači već dugi niz godina izrađuju algoritme za automatsko prepoznavanje slikovnoga sadržaja, stila umjetnika, fotografskih tehnika, televizijskih i video žanrova te ih primjenjuju na većim skupovima podataka. Neke od tih metoda koristi i Manovich za analizu različitih tipova povijesnih i suvremenih vizualnih izvora, npr. za analizu dvadeset tisuća fotografija iz kolekcije u Muzeju moderne umjetnosti u New Yorku (Museum of Modern Art, MoMA), u analizi filmova Dzige Vertova iz Austrijskog filmskog muzeja (Austrian Film Museum), šesnaest milijuna slika dijeljenih putem Instagrama u sedamnaest gradova diljem zemlje, 270 milijuna slika dijeljenih putem Twittera, milijun stranica iz manga stripova i milijun umjetničkih djela s popularne umjetničke mreže DevianArt (Manovich 2022, str. 11).

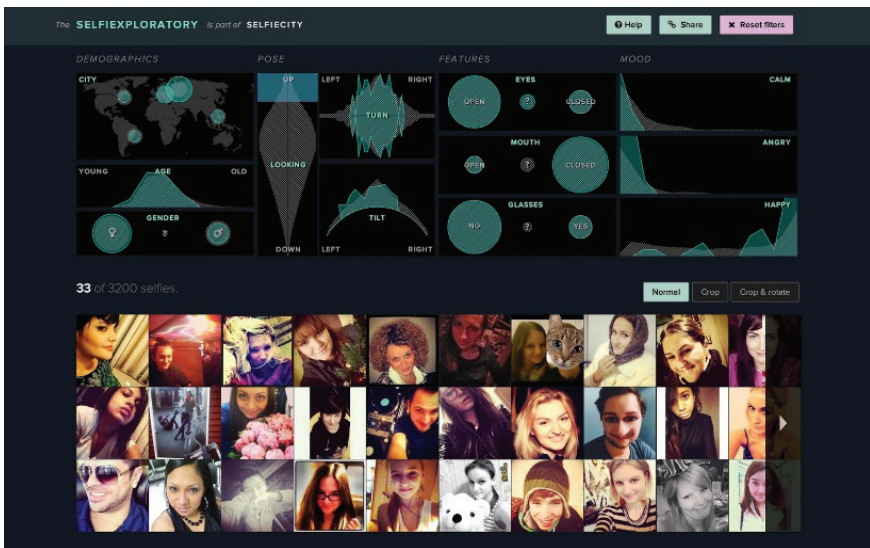


SLIKA 2-4: Radijalna vizualizacija 18941 fotografije u kolekciji fotografija MoMA-e. Razdoblje od 1837. do 2012. Udaljenost slike h od središta određena je godinom nastanka; što je fotografija novija, to je dalje od središta. Stupanj položaja fotografije u krugu određen je njezinom prosječnom svjetlinom.

Izvor: <http://lab.culturalanalytics.info/2016/04/exploratory-visualizations-of-thomas.html>

Manovich u različitim svojim istraživanjima poseže za poznatim metodama u analizi slikovnoga sadržaja, kao što su primjerice tehnike računalnoga vida koje omogućuju detektiranje velikoga broja različitih tipova objekata unutar fotografije. Inovativnost, međutim, pokazuje u stvaranju novih i različitih oblika sučelja (engl. *interfaces*) i tehnika za promatranje velikih količina kulturnih podataka. Smatra kako čovjek može prepoznati dimenzije smisla, detalje koji mogu biti presudni za analizu te može

smjestiti informaciju u određene kontekste puno bolje nego što to trenutno može bilo koji algoritam. No, ono što čovjek zasigurno ne može odnosi se u prvom redu na sposobnost prepoznavanja određenih trendova i obrazaca na velikom broju podataka istovremeno, npr. u kontekstu milijuna različitih fotografija.



SLIKA 2-5: Slika zaslona s interaktivne aplikacije Selfieexploratory izrađene s ciljem analize skupa podataka na 3840 fotografija portreta.

Aplikaciji je moguće pristupiti putem poveznice: <https://selfiecity.net/#selfieexploratory>
(IZVOR: <http://lab.culturalanalytics.info/2014/08/selfiecity-investigates-style-of.html>)

Specifikum Manovichevih istraživanja očituje se s jedne strane u nastojanju da se distancira od teksta, ali i u tendenciji da svoje analitičke interese usmjeri prije svega prema pokretnim slikama i interaktivnim medijima, sugerirajući na taj način svojevrsno odvajanje od DH-a koja je prvenstveno fokusirana na književni i povijesni tekst, te na arheologiju. No, s druge strane koristeći vrlo slične metodološke postupke te referirajući se

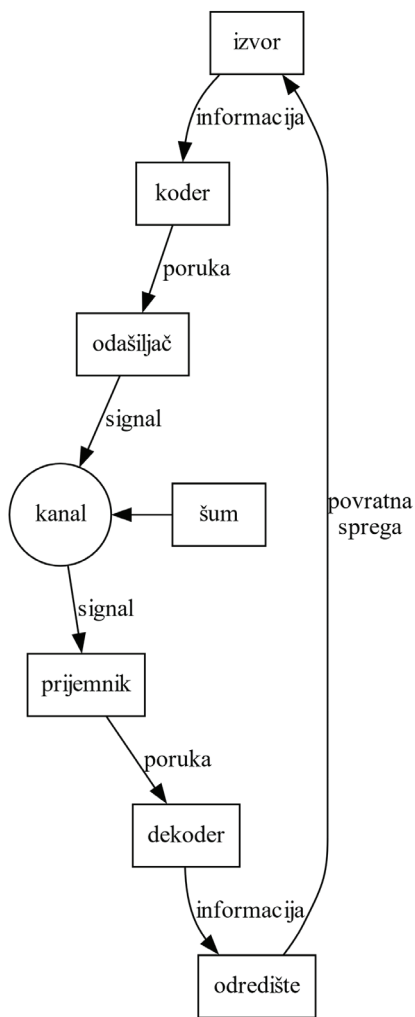
mahom na semiotički teorijski instrumentarij, pravac ili pak metodu koju naziva kulturna analitika ne treba smatrati nekom zasebnom disciplinom samo iz razloga što se udaljuje od teksta i usredotočuje na druge vrste izvora informacija. Držimo, ne misleći pritom kako je naše stajalište suviše pretenciozno, da se kulturna analitika može podvesti pod termin digitalna humanistka, čime se još jednom pokazuje heterogenost discipline i ukazuje na njezine različite smjerove. Naime, i sam Manovich na jednom drugom mjestu u spomenutoj knjizi apostrofira kako je kulturna analitika jedan od mnogobrojnih smjerova koji se od druge polovice 2000-ih godina okušava u interpretaciji i razumijevanju velikoga broja kulturnih i društvenih podataka pa u tom smislu spominje i DH, računalne društvene znanosti, digitalnu antropologiju, digitalnu povijest, urbanu informatiku, itd. S obzirom da se, posebice od sedamdesetih godina 20. stoljeća „tradicionalna“ humanistička istraživanja značajnije udaljuju od kanona i svoja zanimanje sve više usmjeruju prema suvremenim književnim, kulturnim pa i medijskim trendovima držimo kako je izdvajanje kulturne analitike iz okvira DH-a nepotrebno.

Značaj podataka u humanističkim istraživanjima

Iz perspektive klasifikacije znanosti, kako je već prethodno istaknuto, područje humanističkih znanosti veliko je područje s nizom polja i grana pa su tako svakoj disciplini svojstveni vlastiti predmeti i metode istraživanja. Primjena računala u istraživačkim postupcima može se promatrati iz disciplinarnе perspektive pa se onda unutar svake pojedine discipline pojedini istraživački problem može raspravljati s različitih aspekata. Intenzivna digitalizacija raznovrsne građe koja predstavlja predmet humanističkih istraživanja, a koja se ne odnosi samo na izvore koji se čuvaju u knjižnicama, nego i gradivo u arhivima, artefakte koje čuvaju muzeji kao baštinske ili informacijske institucije, dovela je do pojave velikoga broja digitaliziranih ili internetski dostupnih izvora.

Postupkom digitalizacije podatke pripremamo za računalnu analizu. Da bi što jednostavnije objasnili podatke, a onda i sam proces digitalizacije, skupljanja i analize podataka, moramo se vratiti na komunikacijski proces koji je shematski prikazan na Slici 3-1. Claude Shannon²⁷ u svom opisu pojašnjava komunikacijski proces, a detaljnim pregledom cijelog procesa, može se zaključiti da se podatak nalazi u komunikacijskom kanalu, jer je to jedino mjesto gdje se nalazi nešto što je materijalno, nešto što se s nekim prijemnikom, prirodnim ili umjetnim, može percipirati. Za ovaj prikaz dobro je ograničiti se na dio komunikacijskog

²⁷ Claude Shannon, C.E. A Mathematical Theory of Communication *The Bell System Technical Journal*, Vol. 27, str. 379–423, 623–656, July, October, 1948., dostupno na: <https://people.math.harvard.edu/~ctm/home/text/others/shannon/entropy/entropy.pdf>.



SLIKA 3-1 : Komunikacijski proces

procesa od kanala do odredišta. Poruka i informacija su nematerijalni, te postupno nastaju iz signala. Ako za primjer uzmemo tekst napisan na papiru, tada je prijemnik naše oko koje će u kombinaciji s vizualnim koreteksom detektirati postojanje slova na papiru i to predati dalje na analizu. Naš mozak će to dekodirati poznavanjem koda, slova korištenih za zapisivanje, te jezika tog teksta. Rezultat dekodiranja te poruke je informacija koju ćemo primiti.

Shannon kaže da odredište ne mora biti čovjek, može biti i bilo koje živo biće, ali i računalo. Tada signal mora biti čitljiv za računalo, a priprema tog signala za računalo je proces digitalizacije kroz koji se nekakav analogni signal pretvara u digitalni oblik.

Tim procesom se omogućí računalu prijem tog signala ili pak pretvorbu u tip signala koji je jednostavniji za prijem na računalu.

Osim što su informacijsko-komunikacijske tehnologije ovim procesom omogućile očuvanje kulturne baštine, one su jednako tako omogućile i pristup brojnim izvorima informacija te

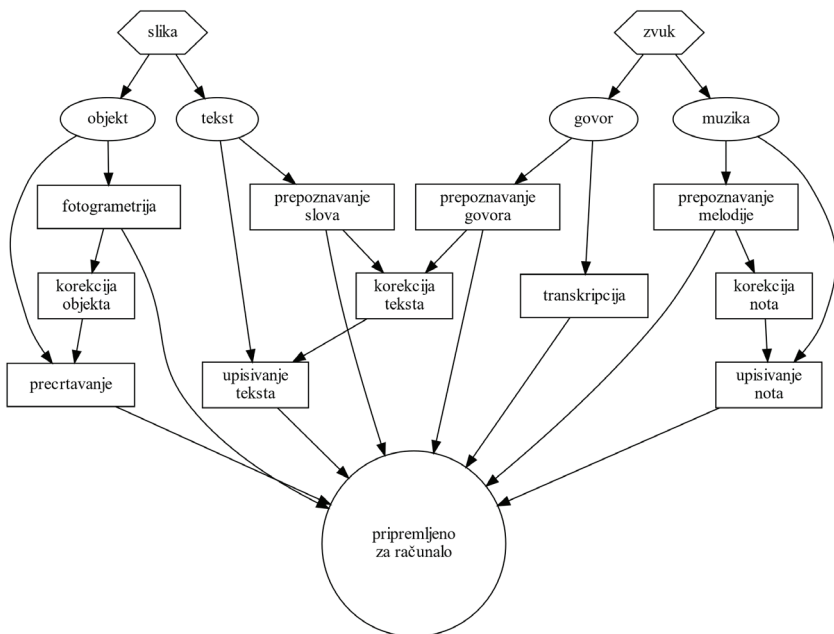
su se na taj način stvorili preduvjeti za razvoj novih mogućnosti istraživanja pomoću računalne obrade. Zahvaljujući digitalizaciji tekst, zvuk i slika prelaze iz domene ljudskoga djelovanja u područje računalnoga. Tako digitalizirani i podaci iz područja humanističkih znanosti postaju pogodni za manipuliranje, tj. za računalnu analizu, što otvara prostor za implementaciju novih metoda istraživanja.²⁸

Povijesni kontekst razvoja i promjena koje je donijela digitalizacija nužan je za cjelovito razumijevanje doprinosa računalne tehnologije istraživanjima u humanističkom području, koje u središte istraživačkih postupaka postavlja analizu i obradu teksta i jezika, zvuka i slike, te objekata. Humanisti su danas, kao i znanstvenici iz svih drugih područja znanosti, izloženi prvenstveno podacima koji ujedno postaju temelj istraživanja. Tada skupljanje podataka i priprema za analizu na računalu postaje najveći problem.

Prikupljanje podataka

Postupak prikupljanja podataka prikazan je na Slici 3-2. Koraci u prikupljanju i digitalizaciji ovise o tipu signala koji se želi analizirati, a shematski je prikazano za vizualne i audio signale. Svako prikupljanje se može odraditi „ručno“, ljudskim prepoznavanjem i unošenjem podataka u računalo, npr. slušanjem snimke razgovora i ukucavanjem transkripta u računalo u obliku teksta. Može biti iskorišteno i automatsko prepoznavanje govora na računalu, ali i poluautomatski, s naknadnim korekcijama u tekstu ako se negdje pojavila nelogičnost ili greška u automatski

²⁸ Za razumijevanje važnosti podataka u kontekstu različitih vrsta istraživanja upućujemo na Kelleher, J. D., Tierney, B. *Znanost o podacima*. Zagreb: MATE d.o.o., 2021. Riječ je o jasno i pristupačno pisanom radu koji se drži nezaobilaznom literaturom u području znanosti o podacima.



SLIKA 3-2 : Prikupljanje podataka

prepoznatom govoru. Priprema zvučnih muzičkih podataka može biti vrlo detaljna, prebacivanjem kompletne melodije u računalo, ručno, poluautomatski ili automatski. Postupak je dugotrajan, pa se ponekad samo zvučna snimka samo opisuje i označava metapodacima koji će kasnije biti iskorišteni za jednostavnije pronalaženje ili klasifikaciju.

Sličan postupak je i za vizualne podatke, koji mogu biti tekst, slika ili pak objekt. Tekstualni podaci se mogu prekućati ili pak uz pomoć računala kroz postupak prepoznavanja slova automatski ili poluautomatski ubaciti u računalo kao tekst koji se može naknadno analizirati. Slika dobije metapodatke koji opisuju što je na slici, te ih se kao i kod muzike može iskoristiti za brže pronalaženje, klasifikaciju i usporedbu. Objekti predstavljaju veći problem jer se

digitalizacija provodi rekonstrukcijom 3D objekta iz fotografija ili pak korekcijama rekonstruiranih objekata ili, u najkompliciranijim slučajevima, crtanjem i oblikovanjem na računalu.

Svaki od ovih postupaka se automatskom upotrebom računala ubrzava, ali se tada gubi sigurnost u ispravno prepoznavanje, jer čovjek taj posao odradi bolje, ali sporije. Ponekad je potrebno prikupiti podatke što je moguće brže, računajući na kasniju potrebu za većom kontrolom i naknadnom korekcijom podataka i mogućom pojavom neispravnih i netočnih podataka.

Ako izvor podataka već postoji u digitalnom obliku, onda je pristup pojednostavljen jer je već dostupan u obliku pogodnom za obradu podataka.

Prikupljanje podataka i pretvorba u oblik pogodan za obradu na računalu je najvažniji proces koji moramo napraviti da bismo uopće krenuli u obradu, analizu i prikaz rezultata. Najdugotrajniji, najkompliciraniji, te najvažniji. Najvažniji jer sve ovisi o kvaliteti odrađenog posla, te pažnji i trudu uloženom u ovaj proces.

Obrada i analiza teksta, jezika, zvuka i govora

Program za oblikovanje teksta prvi je program korišten još od ranih dana rada računala. Tekst kao temeljni materijal za rad i istraživanje pokazao se, a posebice zahvaljujući digitalizaciji, kao odličan način za istraživanje i upravljanje podacima. Digitalna tehnologija ponudila je odlične mogućnosti stvaranja, uređivanja i upravljanja digitalnim dokumentima pa nije čudno što je središnji interes humanista bio usmjeren upravo na alate za manipuliranje tekstem. Danas se broj programa za oblikovanje teksta povećava,

ali se pojavljuju i besplatni alati koji time postaju dostupni svima. Alati dizajnirani za oblikovanje teksta jednostavni su za razumijevanje i korištenje, te su iskoristivi za širok raspon zadataka vezanih uz rad na tekstu.

Uredski paketi, počevši od komercijalnog MS Office paketa, te besplatnog LibreOffice paketa, su alati dostupni za analizu i obradu podataka. Uredski paketi sadrže alate za oblikovanje teksta, alate za numeričku analizu podataka, prezentaciju rezultata analiza, baze podataka, programe za crtanje. Osim paketa koji se instaliraju na računalo, postoje i paketi koji se koriste kroz preglednik, te se izvršavaju kao alati u mrežnom okruženju, alati u oblaku, kao npr. Google Docs/Drive ili MS Office 365/One Drive.

Svi navedeni alati produciraju oblik zapisa koji je računalno čitljiv, te pogodan za brzu računalnu analizu. Uređivači teksta u sklopu uredskih paketa omogućavaju korisnicima prilagodbu i proširenje alata korištenjem ugrađenih programskih jezika, te time pružaju i mogućnost obrade teksta.

Valja istaknuti kako su u hrvatskom istraživačkom prostoru provedena dva značajna projekta²⁹ koja su poslužila kao temelj mnogim kasnijim istraživanjima. Riječ je, naime, o projektima koji su doprinijeli i prikupljanju podataka neophodnih za razvoj sinteze govora za hrvatski jezik.

Naime, kako bi se pisani jezik mogao strojno pretvoriti u zvučni oblik potreban je detaljni opis govornog jezika. Pravila treba detaljno oblikovati kako bi ih računalo uopće moglo primijeniti. Zbog toga je opće prihvaćena činjenica kako je poznavanje

²⁹ Damir Boras, *Teorija i pravila segmentacije teksta na hrvatskom jeziku* i Marko Tadić, *Razvoj hrvatskih jezičnih resursa*.

prozodije jedan od najvažnijih elemenata potrebnih za automatsku sintezu govora, s obzirom da se na temelju prozodijske analize dobivaju važne sintaktičke i semantičke informacije izgovorenoga teksta.³⁰ Najuspješniji algoritmi za predviđanje prozodijskih oznaka bazirani su na ručno pisanim pravilima ili na statističkim metodama, a o čemu ćemo nešto više u dijelu vezanom za obradu zvuka i računalnu sintezu govora.

U kontekstu programa za analizu teksta putem ključnih riječi KWIC i KWOC valja istaknuti Oxford Concordance Program (OCP)³¹. Neovisno o tome na što se fokusiramo u analizi teksta, činjenica jest da je sve zapravo povezano s istraživanjem riječi. U slučaju da je istraživanje usmjereno, primjerice, na oblik riječi (lingvistička istraživanja na osnovnoj razini), na književna istraživanja ili leksikografiju uvijek je u središtu oblik riječi pa je neophodno stvoriti korpus riječi. U nekadašnjem klasičnom pristupu stvaranje takvog korpusa ručnim unosom podataka, obrada i količina obrađenih podataka bila je ograničena. Dostupnost računala i sve veća njihova snaga omogućili su stvaranja korpusa u elektroničkom obliku spremnih za automatsko pretraživanje prema raznim kriterijima. U tom smislu kao posebno zanimljivo područje pojavljuje se računalna stilistika koja se orijentira na istraživanju obrazaca karakterističnih određenom tekstu, autoru, žanru ili razdoblju. Takve analize fokusiraju se na istraživanje

³⁰ Nikolaj Lazić. *Modeliranje strojnih postupaka za izgovaranje teksta pisanoga hrvatskim jezikom, doktorska disertacija, Filozofski fakultet Zagreb, 2006.*

³¹ Program Oxford Concordance prvi put je objavljen 1981. i rezultat je projekta kojeg je Oxford University Computing Services 1978. započeo za stvaranje strojno neovisnog programa za analizu teksta, za izradu popisa riječi, indeksa i konkordancija na raznim jezicima i abecedama. <https://users.ox.ac.uk/~ctitext2/resguide/resources/o125.html>.

učestalosti pojavljivanja riječi u velikom skupu tekstova. Dobiveni podaci podvrgavaju se statističkoj obradi koja se često pojavljuje kao neophodna metoda u proučavanju riječi s visokom frekvencijom pojavljivanja. Vrijednost takvoga istraživanja počiva na činjenici što takve riječi predstavljaju temeljnu strukturu teksta, vidljivu mrežu koja daje oblik onom što je i kako je u tekstu/tekstovima izrečeno. Označavanje vrsta riječi u rečenicama uvodi uporabu skrivenih Markovljevih modela u područje obrade prirodnog jezika. Istraživanja se tako sve više usredotočuju na statističke modele koji stvaraju meke probabilističke granice temeljene na povezivanju težina sačinjenih od realnih brojeva sa značajkama iz ulaznih podataka. Markovljevim lancem možemo direktno utjecati na niz podataka koje promatramo. Za razumijevanje i korištenje modela potrebno je pronaći parametre koji najbolje odgovaraju promatranim podacima te otkriti skriveni niz koji ih emitira. Model se koristio u prepoznavanju govora, a onda i u analizi teksta.³²

Tijekom vremena se pokazao korisnim i za druga područja. Podaci koje trebamo uvijek čine vlastiti korpus tekstova za analizu. Na takvim podacima možemo raditi različite statističke analize ili izraditi aplikaciju za obradu prirodnog jezika. Kao primjer valja izdvojiti NooJ³³ koji nudi formalne alate za stvaranje, testiranje, popravljavanje i dijeljenje jezičnih resursa sa širokom pokrivenošću za mnoge jezike. NooJ je također integriran u mnoge NLP (engl. *Natural Language Processing*) aplikacije: prepoznavanje imenovanih entiteta, automatsko generiranje teksta, sučelje prirodnog jezika, konceptualna tražilica, automatska proizvodnja parafraza, seman-

³² Nikolaj Lazić. *Modeliranje strojnih postupaka za izgovaranje teksta pisanoga hrvatskim jezikom*, doktorska disertacija, Filozofski fakultet Zagreb, 2006.

³³ Više informacija na stranici www.nooj-association.org.

tički web, strojno prevođenje. NooJ podržava Metashare program Europske zajednice, besplatan je i otvorenog koda i radi pod Windowsima, Mac OSX, LINUX i Unix. Postoje moduli jezičnih resursa u NooJ formatu za više od 20 jezika, uključujući i hrvatski jezik.³⁴

Danas postoji čitav niz edukacija u virtualnom okruženju koje humanistički znanstvenici mogu pohađati i kojima zasigurno mogu steći znanja za početne korake u suvremenom digitalnom okruženju. Takve edukacije organiziraju, između ostalih i tvrtke poput Udemy (<https://www.udemy.com/>), Coursera (<https://www.coursera.org/>), itd., te su namijenjene polaznicima bez ili s minimalnim poznavanjem programiranja. Izdvajamo na ovome mjestu edukaciju iz područja obrade prirodnoga jezika (engl. *Natural Language Processing in Python for Beginners*) na kojoj polaznici mogu steći široki spektar znanja, npr. od uvodnih predavanja o strojnom učenju i pisanja početničkog kôda u Pythonu do znanja iz područja statistike. Jednako tako, moguće je razumijeti, ali i samostalno raditi na konkretnim primjerima u smislu tokenizacije, lematizacije; moguće je upoznati se s načinima rada s različitim vrstama datoteka; razumijeti proces „čišćenja“ i pripreme teksta za analizu; pratiti objavljivanje poruka na Twitteru u stvarnom vremenu te izraditi analizu sentimenta. Jednako tako, u sklopu ove edukacije korisnici se mogu upoznati s čitavim nizom besplatnih alata koji olakšavaju rad u području obrade prirodnoga jezika, od čitavoga niza softverskih knjižnica pisanih za programski jezik Python (npr. Pandas, NumPy, Matplotlib, itd.) do spaCy-a, softverske knjižnice otvoreno-

³⁴ *Journal of Computing and Information Technology - CIT* 18, 2010, 4, 295–301
doi:10.2498 /cit.1001914 295 Croatian Language Resources for NooJ Kristina
Vučković, Marko Tadić and Božo Bekavac, Faculty of Humanities and Social
Sciences, University of Zagreb, Croatia

ga koda pisane za naprednu obradu pisanoga jezika, napisane u programskim jezicima Python i Cython. Svi navedeni alati, također, su besplatni, a spaCy jednako tako posjeduje podršku za hrvatski jezik.

Računalna obrada govora

Govor kako temeljni čovjekov komunikacijski alat oduvijek je privlačio pažnju brojnih znanstvenika. Govor kao signal koji nosi informaciju (akustički valni oblik), korištenjem i jačanjem tehnologije i novim sustavima temeljenim na suvremenim tehnologijama koje sadrže algoritme digitalne obrade govora, usmjerio je istraživačke interese prema primjeni postupaka digitalne obrade govora u brojna područja.

Tako se ideja o komunikacijsko-tehnološkom napretku suvremenoga društva i pomagalima koja su u raznim vremenima sudjelovala u pretvaranju zvučnog signala u svrhu jezične komunikacije, kao tek jedna od metoda koju ljudi koriste s ciljem i u svrhu komunikacije, pretvorila u istraživanja primjene računala u području jezika i govora. Programi za prepoznavanje glasa i govora danas su toliko napredovali da aplikacije koje koriste algoritme za prepoznavanje glasa i govora mogu analizirati zvuk, te taj isti zvuk potom pretvoriti u tekst. Razvijen je i softver za konferencijske sustave i udaljeno učenje, posebno su brojni programi za prepoznavanje govora i govornika te sustavi za detekciju riječi, sustavi za poboljšanje kvalitete govora te programi za analizu govora u svrhu dijagnostike raznovrsnih problema ili oboljenja. Istraživanja pokazuju kako se gotovo sve velike tvrtke kao što su npr. Apple, Microsoft i Google natječu danas u izradi aplikacija koje koriste algoritme za prepoznavanje govora.

Skupljanje podataka iz zvučnog zapisa može se odraditi i ručno, npr. korištenjem alata za označavanje, transkripciju riječi i zvukova produciranih u govoru i kasniju analizu tih oznaka. Primjer je program za analizu govora u svrhu dijagnostike raznovrsnih problema govora, koji može poslužiti kao model za neka daljnja istraživanja. Jedan takav model je i LARSP³⁵ (engl. *Language Assessment Remediation Screening Procedure*) koji objedinjuje nekoliko kliničkih postupaka kako bi se osigurala precizna dijagnostika i uspješna rehabilitacija dječjeg govora i jezika. Za točnu dijagnostiku potrebna je detaljna analiza. Ona se za LARSP vrši na transkribiranom dječjem govoru, snimljenom u propisanim kontekstima i uz pomoć standardiziranih materijala. Za izradu programa koji je pripremljen za hrvatski jezik odabran je programski jezik Python, koji je korišten baš zato što je pogodan kako za obradu teksta, tako i jezika.³⁶ U svrhu ubrzanja i olakšanja analize stvoren je alat LARSPTool koji osim brže analize većega korpusa, uvodi i novi standard i jednodimenzionalnost prikaza podataka što znatno pridonosi učinkovitosti ove metode.

Istraživanja u području sinteze govora kreću od opisa pretvorbe pisanoga jezika u govorni do samog trajanja glasa. Ono što je važno kod korištenja teksta za sintezu govora jest da ulazni podaci pretvaraju u oblik u kojemu ih se može dalje primijeniti, a

³⁵ John H. Connolly, Language Assessment, Remediation and Screening Procedure A commentary on the LARSP procedure, July 2009. *International Journal of Language & Communication Disorders* 19(1):63-71 DOI:10.3109/13682828409019836.

³⁶ Tot, Bruno; Lazić, Nikolaj; Mildner, Vesna. Automatsko označavanje i analiza teksta za LARSP hrvatskoga jezika. *Zbornik radova s Međunarodne doktorske konferencije za doktorande poslijediplomskih sveučilišnih doktorskih studija upodručju Medija i komunikacije*. Koprivnica: Sveučilište Sjever, 2022. str. 100-108.

pritom treba znati da tu postoje problemi koje treba riješiti u samoj predobradi teksta, kao na primjer; brojevi, skraćénice i akronimi. Obrada teksta obično se izvodi pomoću jednostavnih tabelarnih prikaza, no u nekim su slučajevima potrebne dodatne informacije o susjednim riječima ili znakovima. To može rezultirati velikom bazom podataka i složenim nizom pravila, a može prouzročiti i neke probleme kod sustava koji rade u realnom vremenu, pa se podaci često spremaju u hijerarhijske oblike. Prvi zadatak sustava pretvorbe teksta u govor je pretvorba ulaznog teksta u znakove lingvističkog prikaza i taj postupak obično nazivamo fonetička pretvorba teksta ili grafemsko-fonemska pretvorba. Problemi na koje se može naići prilikom te pretvorbe u prvom redu ovise o konkretnom jeziku. S hrvatskim jezikom takvu je pretvorbu poprilično jednostavno provesti budući napisani tekst gotovo u potpunosti odgovara svojoj izgovorenoj verziji, u smislu da gotovo svaki pojedini grafem pisanog teksta odgovara pojedinom fonemu. Kod drugih jezika pretvorba je znatno složenija. Postupak pretvorbe može se podijeliti u tri glavne faze – obrada teksta, osmišljavanje lingvističkih podataka potrebnih za ispravan izgovor i analiza prozodijskih obilježja nužnih za ispravnu intonaciju, naglasak i trajanje. Kod obrade teksta brojke, posebni znakovi, skraćénice i akronimi proširuju se u cijele riječi. Kod sinteze visoke razine³⁷ ulazni tekst ili podaci transkribiraju se u formatu koji omogućuje da glasovni sintetizator niske razine proizvede akustičko djelovanje. Uspješna primjena te zamisli predstavlja temeljni izazov. Nakon što sintetizator visoke

³⁷ Postupci su detaljno opisani u doktoratu *Modeliranje strojnih postupaka za izgovaranje teksta pisanoga hrvatskim jezikom, doktorska disertacija*, Filozofski fakultet Zagreb, 2006., Nikolaja Lazića. Valja istaknuti kako se postupci tijekom vremena nisu mijenjali.

razine obradi prikupljene podatke oni se obrađuju kroz određeni sustav niske razine što bi trebalo rezultirati konkretnim djelovanjem toga sustava. Vrsta korištenih podataka ovisi o pokrenutom sustavu. Na primjer, kada se koristi formantni sintetizator govora nužno je raspolagati podacima o osnovnoj frekvenciji, frekvencijama formanata, trajanju i rasponu svakog pojedinog zvuka.

Prikupljanje podataka iz zvučnih snimki može se odraditi korištenjem programa za analizu zvuka Praat³⁸ i alata izrađenih u ugrađenom programskom jeziku. Primjer ispod je program za izvlačenje prozodijskih obilježja glasova u označenom zvuku, napisan u skriptnom jeziku programa Praat. Ulazni podaci za program su označeni zvuk, kontura osnovne frekvencije i kontura intenziteta zvuka unutar označenog zvuka. Rezultat je izlazni set podataka u kojem se nalaze popisi trajanja segmenata i dijelovi osnovne frekvencije i intenziteta u tim segmentima prema oznakama koje korisnik postavi za odabrani zvuk. Izlaz je u obliku teksta čitljivog u bilo kojem programu za prikaz teksta.

```
brojtocaka=20
izlaznifile$="izlaz.csv"
odvojisa$=" *      "
seed=1768843598
select all

fileova=numberOfSelected("TextGrid",j)
for j from 1 to fileova
  im'j'=selected("TextGrid", j)
endfor
```

³⁸ Program Praat dostupan je na: <http://praat.org>.

```

tekst$=""
tekst$ > `izlaznifile$`

for k from 1 to fileova
  select im`k`
  trenGrid=selected()
  imes$=selected$("TextGrid")
  btiera=Get number of tiers
  j = 3
  while j<=btiera
    intervalni=Is interval tier... `j`
    if intervalni
      ntier$=Get tier name... `j`
      komada=Get number of intervals... `j`
      for i from 1 to komada
        start=Get starting point... `j` `i`
        kraj=Get end point... `j` `i`
        traje=kraj - start
        ime$=Get label of interval... `j` `i`
        if ime$!=""
          tekst$=imes$+tab$+ntier$+
            ... tab$+"`i`"+tab$+ime$+
            ... tab$+"`traje`"+tab$
          select Pitch `imes$`
          for n from 0 to brojtocaka-1
            vrijemeuzorka=start+n*traje/brojtocaka
            uzorak = Get value at time...
            ... `vrijemeuzorka` ERB Linear
            if uzorak!=undefined

```



```

        tekst$=tekst$+""uzorak'"
    endif
    if n<brojtocaka-1
        tekst$=tekst$+tab$
    else
        tekst$=tekst$+tab$
    endif
endfor
tekst$=tekst$+""odvojisa$'"'+tab$
select Intensity `imes$'
for n from 0 to brojtocaka-1
    vrijemeuzorka=start+n*traje/brojtocaka
    uzorak = Get value at time...
    ... `vrijemeuzorka' Cubic
    if uzorak!=undefined
        tekst$=tekst$+""uzorak'"
    endif
    if n<brojtocaka-1
        tekst$=tekst$+tab$
    endif
endfor
tekst$=tekst$+newline$
tekst$ >> `izlaznifile$'
select trenGrid
endif
endfor
endif
j=j+1

```

endwhile
endfor

Ovaj program je primjer izvlačenja podataka iz zvuka prema oznakama koje je postavio čovjek, ekspert u tom području. Podaci se nakon toga mogu statistički analizirati za potrebe analize prozodije u rečenici na nivou riječi ili rečenice. Primjer takve naknadne analize podataka o prozodiji je praćenje i analiza intonacije rečenice u govoru,³⁹ a označeni govorni zvuk može postati i izvor podataka za automatsko prepoznavanje govora korištenjem umjetnih neuronskih mreža.

Niz ovdje spomenutih i skromno opisanih alata za obradu prirodnog jezika, teksta i govora uistinu može podržati iznimno široki raspon znanstvenih aktivnosti. Ograničenost prostora, ali i zamisao da se ovom knjigom tek otvori put u široko područje humanističkoga računalstva i digitalne humanistike, navodi nas na upozorenje kako prethodne retke valja shvatiti kao nagovještaj dubljega uranjanja u navedenu problematiku koja će se u budućim izdanjima detaljnije obrazlagati u kontekstu konkretnih istraživačkih problema. Pogled u budućnost i mogućnosti koje su pred nama zahtijevaju veća ulaganja u znanje i vještine, a kroz sljedeća poglavlja samo smo odškrinuli prozor u taj novi svijet digitalnih alata, računalnog mišljenja i novih metoda rada korištenjem računalne tehnologije.

³⁹ Stojanović, A. (2019). *Metoda automatske detekcije naglašenih riječi u zvučnom zapisu* (Disertacija). Zagreb: Sveučilište u Zagrebu, Filozofski fakultet. Preuzeto s <https://urn.nsk.hr/urn:nbn:hr:131:248144>

Obrada podataka

Podaci su nositelji znanja pohranjenih u različitim izvorima pa glavna preokupacija humanista postaje razumijevanje načina na koje i razloga zbog kojih njihov predmet istraživanja poprima obilježja numeričke kategorije. Tek nakon što se razumije priroda funkcioniranja računalnih tehnologija, moguće je pristupiti usvajanju temeljnih znanja i vještina iz područja računarstva potrebnih za konkretnu primjenu konkretnih alata u različitim vrstama istraživanja. Stoga se danas od humanističkoga znanstvenika očekuje sposobnost eksplicitnoga iznošenja znanja o predmetu istraživanja i razumijevanje načina na koji se taj predmet može istražiti i predstaviti uz pomoć računalnih alata. Naime, svaki istraživački problem može se predstaviti nizom podataka, a u računalno potpomognutoj analizi velikih količina podataka koji su kodirani i precizno obrađeni, svaki korak u pripremnoj fazi istraživanja kao i oni koraci koji potom slijede moraju biti jasno definirani. Iz navedenoga nije teško zaključiti kao računalo naprosto ne funkcionira na dvosmislenostima, nego od nas traži jasnoću i preciznost u postavljanju zahtjeva.

Egzaktne metode iscrpnog pretraživanja i dinamičkog programiranja, primjena konstruktivnih, hibridnih i metaheuristika za rješavanje praktičnih problema otkrivaju novo područje istraživačkih metoda za humanističke znanosti. Računalne metode omogućuju analizu određenih značajki podataka, što daje novi pogled na dosad poznati sadržaj i omogućuje potencijalno otkrivanje novoga znanja. Takav heuristički koncept temeljen na suradnji znanstvenika iz različitih područja znanosti potiče i usmjerava na pronalaženje i otkrivanje novih znanja. Uvesti humaniste u taj novi

svijet računalnog razmišljanja i numeričkih metoda znači otvoriti im svijet algoritama, programskog kôda i programskih jezika. Riječ je o jezicima posebne namjene čija je svrha prevesti stroju instrukcije na za njega razumljiv način. Programski jezici uveli su nove koncepte računalnog načina mišljenja koji nisu imali sličnosti s intelektualnom tradicijom humanističkog jezika i mišljenja.

Metodologija programiranja (koja nije bliska humanističkim znanstvenicima jer nije uključena niti u sustav njihova obrazovanja, niti način mišljenja) i sama arhitektura računalnih sustava bila je, a nerijetko još uvijek i jest, glavna prepreka samostalnog korištenja računalnih metoda u istraživanju u DH području. Štoviše, veliki broj inovacija kojima svjedočimo, poput primjerice obrade prirodnog jezika, strojnog učenja, a onda i analize i prepoznavanja slika i govora omogućene su zahvaljujući računalnoj obradi. No, činjenica jest da je za svaku od tih primjena potrebno stvoriti novi alat. Naime, svaki humanistički projekt, svaka novo postavljena premissa koja zahtjeva dublju analizu i istraživanje zahtijevat će specifičan upravo tom problemu namijenjen alat. Otuda i sve jasnija potreba za uvođenjem humanističkih znanstvenika u područje računarstva i potreba za svojevrsnim osamostaljenjem u ovom području. Jer, za razliku od kakvoga inženjera ili programera, humanist najbolje poznaje građu i predmet vlastitoga istraživanja pa je iz toga razloga i pozvan da samostalno izradi alat koji će mu predstavljati pomoć u analizi i predstavljanju rezultata istraživanja.

Dakako, u početnoj fazi koja podrazumijeva uvođenje u područje računalnih tehnologija, pomoć računalnih znanstvenika neophodna je za razumijevanje i korištenje metoda i alata. Međutim, valja istaknuti kako susret humanističkih znanosti s računal-

nim tehnologijama značajno olakšavaju novi jezici i alati, poput primjerice Pythona.⁴⁰ Ovaj je alat intuitivan i daleko lakši za učenje i uporabu, nego neki drugi programski jezici, kao što je npr. C++.

Kako je prethodno već istaknuto, primjena računala u kontekstu tekstualnih izvora zauzela je središnje mjesto u razvoju humanističkog računalstva, pa će iz toga razloga u nastavku nešto više biti kazano o pojedinim metodama i alatima za obradu teksta.

⁴⁰ Python je programski jezik opće namjene, interpretiran i visoke razine kojeg je stvorio Guido van Rossum 1990. godine, ime dobiva po televizijskoj seriji Monty Python's Flying Circus. Po automatskoj memorijskoj alokaciji, Python je sličan programskim jezicima kao što su Perl, Ruby, Smalltalk itd.
[https://hr.wikipedia.org/wiki/Python_\(programski_jezik\)](https://hr.wikipedia.org/wiki/Python_(programski_jezik))

Metode umjetne inteligencije

Godina je 2018. U dvorani za plenarne sjednice Münchenskog sajma na godišnjoj konferenciji tvrtke NVIDIA okupilo se oko 2500 sudionika, uglavnom mlađarije, gotovo iz svih kutaka svijeta. Iz tame pozornice, osvijetljen šturim snopom svjetla, pojavio se govornik, po procjeni autora u ranim pedesetima, odjeven u crno, s crnom kožnom jaknom na sebi, za koju će se kasnije ispostaviti da je to njegov "zaštitni znak". Iz prvih minuta njegova nastupa autor je, posve pogrešno, zaključio da je riječ o unajmljenom pripovjedaču, koji ima zadaću ne samo izložiti tvrtkina dostignuća u razvoju i proizvodnji grafičkih procesora, posebice onih namijenjenih neuronskim mrežama i dubokom učenju, već i zaokruženih računalnih sustava (Teslino ime nije spominjano uzalud; Slika 4-2) te usput zabavljati publiku. Ispostavilo se da je govornik ni manje ni više negoli Jensen Huang, suosnivač i CEO tvrtke NVIDIA. Izlaganje je bilo vrlo upečatljivo, popraćeno povremenim doskočicama na račun tehničkog pomoćnika koji je iz dubine tame pod svjetla pozornice iznosio čudesne „gadžete“, čiji prikazi su se izmjenjivali sa video-isječcima prepoznavanja lica u realnom vremenu, autonomne vožnje, itd.

Kao zvučni vatromet dvoranom su u valovima odjekivale sintagme „strojno učenje“ i „umjetna inteligencija“. Međutim, ono što je autora najviše iznenadilo (da ne kažemo zapanjilo) jest činjenica da je pod „umjetnom inteligencijom“ podrazumijevana isključivo „osjetilna inteligencija“, poput „inteligencije“ nužne za raspoznavanje lica, gestikulacije plesača na podiju ili dirigenta na koncertnoj pozornici, sudionika (ljudi, vozila,...) prometa u

stvarnom vremenu i tome slično.



SLIKA 4-1: Izlaganje Jensena Huanga na plenarnoj sjednici konferencije NVIDIAGTC, svibanj 2018.




SLIKA 4-2: Unutrašnjost računala DGX-2, sa 16 procesora TESLA T4, prikazanog na istoj konferenciji.

Da se vratimo na naglaske s konferencije, iako je posve jasno da, primjerice, autonomna vožnja automobila nije moguća bez donošenja odluka vezano za upravljanje njime (držanje razmaka prema drugim vozilima, pretjecanje, pravovremeno kočenje, ponašanje na semaforima, poštivanje pravila prednosti, poštivanje prometnih znakova, promjena trase ovisno o informacijama o

zastojima na pojedinim segmentima, radovima, privremenim zabranama, vremenskim uvjetima,...), o tome aspektu umjetne inteligencije, koji uključuje „kognitivnu inteligenciju“, uključujući i logičko zaključivanje temeljem poznatih činjenica, i općenito, *rezoniranje o znanju*, nije se čulo ni slova.

Situacija u prometu ne treba uopće biti složena kao ova na Slici 4-3, da bi, pored elemenata osjetilne inteligencije, nužno uključivala i elemente kognitivne inteligencije, točnije, elementa rezoniranja o znanju u *višeagentnom sustavu*, gdje ulogu agenata igraju pješaci i vozači (ili sustavi autonomnog upravljanja vozilom bez vozača). Dovoljno je promotriti jednostavnu prometnu situaciju, ograničivši se na donji lijevi dio Slike 4-3 s pješakinjom sa zelenim svjetlom za prijelaz preko zebre i motoristom koji također ima slobodno skretanje udesno.



SLIKA 4-3: Moguća prometna situacija na cestovnom križanju.

Pješakinja zna da ona ima prednost prijelaza, ali zna da to zna i motorist, dok motorist zna da pješakinja zna da on to zna, jer se inače ne bi usudila slobodno krenuti preko zebre. Također,

pješakinja zna da motorist zna da ona zna da motorist zna da ona ima prednost prelaska preko zebre,...

Ovakvo iterirano znanje u višeagentnim sustavima poznato je kao *zdravorazumsko znanje* (engl. *common knowledge*). Takva vrsta znanja jednostavno je usađena u ljudsku inteligenciju i oko nje se u situacijama poput ove na semaforu posebno i ne trudimo.

Međutim, autonomno vozilo koje bi se našlo u situaciji kao na Slici 4-3 tu vrstu znanja moralo bi imati ugrađenu u svoj sustav upravljanja. To nas dovodi do potrebe razmatranja formalizacija sustava znanja i automatske dedukcije. Tu se nalazimo ispred golemog područja istraživanja, u rasponu od čisto teorijskih pa do posve praktičnih.

Prije negoli se pozabavimo samim izlaganjima, moramo se osvrnuti na činjenicu zazora od apstraktnog mišljenja općenito, posebice zazora od „formula“ i „formalizacija“, uočene tijekom dugih godina podučavanja (preko 25 različitih kolegija) na sveučilišnoj razini. Međutim, unatoč tome zazoru, čak i o tome uopće ne misleći, brojne apstrakcije koristimo i u svakodnevnom životu. Tako, primjerice, suvereno se koristimo svojim poimanjem „točaka“, „pravaca“ i „ploha“ u stvarnom prostoru. Međutim, u tome prostoru „točke“, „pravci“ i „plohe“ u strogom smislu **ne postoje**⁴¹. One su samo korisne *aproksimacije* i zapravo „postoje“ jedino stoga što su korisne. Bez apstraktnog mišljenja i stvaranja formalnih modela (teorija) stvarnosti znanost i tehnologija jednostavno su nezamislivi.

⁴¹ Ipak, autorov davni instruktor vožnje, znajući za njegovo matematičko obra-zovanje, opetovano i neumorno se raspitivao o tome gdje se nalazi „središte točke“. Nismo se uspjeli dogovoriti.

U tom smislu, povijest razvoja znanosti vrvi primjerima dobre (ali i loše) prakse. Prisjetimo se, primjerice, nemjerljivog procvata aritmetike nakon uvođenja *pozicijskih brojevnih sustava* (dekadskog⁴² (dobra praksa) umjesto rimskog (loša praksa)), procvata algebre nakon uvođenja *valjane notacije* (Francoise Viette), procvata elementarne geometrije nakon njezine *aksiomatizacije* od strane Euklida, te zatim i neeuclidskih geometrija, procvata elektromagnetizma nakon *formulacije njegovih temeljnih zakona* od strane Maxwella, i nebrojenih drugih.

Izrazit zazor kod slušateljstva autor je osjetio u kontekstu izlaganja sustava simboličke (matematičke) logike i formalnih jezika, bez kojih danas ne bi bilo ni programskih jezika, baza podataka, kriptografije, Weba, računala, mobilnih mreža, itd.

A sasvim usput, bili bismo zakinuti i za brojevne identitete, poput čuvenog (i čudesnog) Eulerova:

$$e^{i\pi} = -1$$

gdje su e i π *transcendentni*⁴³ brojevi, a i *imaginarna jedinica* ($\sqrt{-1}$). Nakon ovoga, znamo li uopće što je potenciranje?!⁴⁴

⁴² Prema nekim povijesnim izvorima, računanje s dekadskim zapisom brojeva koje je u srednjovjekovnu Europu došlo iz arapske kulture, u početku je, slijedom brzine izračunavanja u odnosu na do tada uvriježeni sustav tzv. *rimskog* zapisivanja brojeva, smatrano čak nekom vrstom *vradžbine* i bilo izloženo napadima za *herezu*.

⁴³ Ne mogu biti korijeni/rješenja niti jedne algebarske jednadžbe s cjelobrojnim koeficijentima

⁴⁴ Ako smo sigurni da znamo što je *prost broj* (broj koji je djeljiv samo s 1 i samim sobom), onda znajmo i to da je broj n prost broj ako i samo ako je viševaljana logika Lukasiewicza F_{n+1} predpotpuna u logici Posta P_{n+1} . Znamo li nakon ovoga *što je to prost broj uopće?*! Ovo ne pišemo da bismo čitatelja *zaplašili*, već upravo suprotno, da bismo ga *potaknuli* na neprekidnu znatiželju prema svijetu (znanosti,...)

Po osobnom mišljenju autora, taj zazor od apstraktnog mišljenja na neki način je naučen i društveno nametnut. Pa su, s jedne strane, mladi ljudi koji pokazuju interes za matematiku, fiziku, logiku, i općenito egzaktne znanosti, „štreberi“, dok su s druge strane oni koji znaju napisati, karikirano govoreći, dva retka programskog kôda, jer je to u javnom prostoru „in“, odmah „genijalci“. Nažalost, istinskim „genijalcem“ ne može se postati a da se istodobno ne bude i „štreberom“.

Međutim, površan, pa čak i ignorantski odnos prema učenju i znanju, nije od jučer. Pokazuje to i citat iz romana *BEL-AMI*, francuskog pisca Guya de Maupassanta iz 1885. g., prema hrvatskom izdanju (Maupassant, 1994, str. 13).

Georges Duroy, mladi čovjek, nastanjen u Parizu, slabo plaćena posla, sreće starog ratnog druga Forestiera, koji se, želeći mu pomoći u novinarskoj karijeri jer je i sam iskusan novinar na solidnoj poziciji u pariškom dnevnom listu »Francuski život«, raspituje o Duroyevu obrazovanju:


***BEL-AMI*: dijalog između Du Roya i Forestiera**

- Jesi li maturirao?
- Nisam. Pao sam dvaput.
- Svejedno, glavno da si završio školovanje. Ako se govori o Ciceronu ili o Tiberiju, ti znaš, po prilici, o čemu je riječ?
- Znam, otprilike.
- Dobro, nitko i ne zna o tome više osim dvadesetak budala koje nisu u stanju da se iskoprcaju. Nije teško postići da te smatraju obrazovanim, glavno je dopustiti da te ne uhvate *in flagranti* u neznanju. Migoljiš se, izbjegavaš poteškoće, obilaziš prepreke i zbunjuješ druge s pomoću rječnika. Svi su ljudi glupi kao guske i neuki kao ribe.

Ovdje autor ne može odoljeti čitatelju ispričati jedno osobno iskustvo, unikatno možda i u „svjetskopovjesnim“ razmjerima, o odnosu „struktura“ prema znanosti i znanstvenicima. Priča ide ovako (ovaj put u prvom licu). Dokumentacija je davno nestala pa će čitatelj morati autoru vjerovati na riječ:

Godina je 1988. Spremam se pisati knjigu *Matematička logika za ekspertne sisteme*. Sadržaj knjige i ugovor s izdavačkom kućom Informator iz Zagreba imam. Knjigu kanim pisati na računalu, ali nemam ni računalo, kao ni program za pisanje koji bi podržavao matematički slog, a ni pisač. Tržištem kućnih ili stolnih računala prevladavaju računala Comodore, s maksimalno 64K memorije. Microsoft razvija tzv. PC-XT, pod jednom od ranih verzija operacijskog sustava MS-DOS. Od programa za pisanje za PC-XT tu je Word Perfect, s nikakvom podrškom za matematički slog. Može se nabaviti TEX profesora Knutha (na pedesetak disketa), ali je teško doći do literature za nj i sve je k tome strašno sporo. Appleova računala izuzetno su skupa i teško dostupna. Rješenje se pojavilo u obličju računala Atari 1040 STF, istoimene tvrtke. Njegov operacijski sustav nekakva je inačica operacijskog sustava UNIX, osnaženog za to vrijeme izuzetno kvalitetnim grafičkim sučeljem. Tu je i miš, kao i disketna jedinica za diskete kapaciteta 750K. U ondašnjem znanstveno-popularnom časopisu *Galaksija*, jedinom u kojem se na redovitoj mjesečnoj osnovi moglo doznati novosti iz svijeta računala, nalazim priručnik za program Signum 2 za računalo Atari. Po svojoj funkcionalnosti, ako se uspoređi sa sadašnjim programskim alatima iste namjene, on je bio nekakva skućena kombinacija programa za uređivanje teksta (Word), programa za prijelom (InDesign, QuarkXPress,...) i programa za

uređivanje fontova (FontLab, Font Forge, Fontographer,...). Kasnije su razvijene i značajno unaprijeđene inačice programa, koje su, kao što je to danas uobičajeno, koristile vektorske, a ne bit-mapirane fontove. Posljednja razvijena inačica bila je Signum 4.4. Kako je tvrtka Atari, slijedom nerazumne poslovne politike, uznastojeći na zatvorenost svojih računalnih sustava, propala, tako je minula i slava programa Signum. Da ga je malo modernizirati i reimplementirati pod suvremenim operacijskim sustavima, posve sam siguran da bi i danas bio u rangu najboljih programa svoje vrste.



SLIKA 4-4: Priručnik za aplikaciju Signum 2 za računalo Atari 1040 STF.

Dakle, da se vratim s ove male digresije, ostaje nabaviti računalo, pišač i program Signum 2, i krenuti pisati. To je povelik izdatak, otprilike tri moje mjesečne plaće. Dovijajući se kako ga

smanjiti, u jednim tadašnjim službenim novinama (Službeni list SFRJ, 10, 1976.) nalazim da povratnici iz inozemstva, nakon određenog broja godina provedenih na radu izvan zemlje, imaju, uz oslobođenje od carine, među ostalim, i pravo uvesti osobno računalo. To hvale vrijedno pravo popratila je i jedna kaznena odredba, po kojoj pravo korištenja računala, nabavljenog pod povlaštenim uvjetima, ima isključivo vlasnik povlastice. Bude li tko drugi zatečen u neovlaštenom korištenju dotičnog računala, bit će prekršajno kažnjen. Pročitavši taj stavak zakona samo sam se nasmijao toj birokratskoj zadrnosti, ne uzimajući je ozbiljno, što će se poslije pokazati poprilično naivnim.

Nekako se poklopilo da se iz Australije, nakon godina boravka i rada, netom vratio jedan moj daljnji rođak. Sa sobom je donio debeli svežanj potvrda o mjesečnim primanjima i plaćenom porezu (čini se da je fiskalizacija u Australiju doprla s prvim kažnjeničkim brodom koji je doplovio do njezinih obala). Rođak mi je rado ustupio svoja prava na kupnju računala, uz uvjet da samu kupnju i sve formalnosti u njegovo ime obavim ja sam.

Tako smo se kolega s posla, Goran Belamarić, i ja, u ranu jesen '88. uputili ravno u München, svaki po svoj Atari 1040 STF. Od rođaka sam ponio ondašnji pasoš i kopije svih zakonskih propisa za koje sam mislio da će mi zatrebati za carinske vlasti na granici. Već u dolasku na slovensko-austrijsku granicu, carinik, kojem smo rekli kamo i po što idemo, odrješito nam je rekao da se računala za osobne potrebe ne mogu uvoziti. Nakon što sam se pozvao na zakon po kojem je to ipak moguće, rekao mi je da sam ja „opasan“.

Kupnju u Münchenu obavili smo uspješno i negdje kasno

u noći drugog dana opet banuli na granicu. Svu opremu uredno smo prijavili, i uz nekoliko opetovanih istovarivanja i utovarivanja u automobil, zgražanje carinika na kupnju pisača i čekanje da carinsku procedure prije nas obave svi vozači kamiona-tegljača, ispraćeni krajnjom neljubaznošću carinika i policajaca na izlaznoj rampi, uputili smo se natrag u Varaždin, i u nj sretno stigli negdje oko podneva trećeg dana po odlasku na put. Nakon puna dva i pol dana nespavanja (vrlo nestvarno i poučno iskustvo!) i odspavanih dvadeset i četiri sata u komadu, s veseljem sam zaključio kako je najgore prošlo.

Istog dana, kupljeno računalo i opremu, prijavio sam, s rođakom kao kupcem, varaždinskoj ispostavi koprivničke carinarnice, zatraživši, naravno, u njegovo ime, oslobođenje od carine.

Isprva je sve teklo glatko, rođakov pasoš trebao je biti dovoljan za ostvarenje carinske povlastice, ali su se stvari iznenada počele komplicirati. Za rođaka je sad trebalo dostaviti i izvatke o primanjima u Australiji i potvrde o na njih plaćenom porezu. To me je stajalo jednog neplaniranog putovanja u Liku po prilično neugodnom jesenjem vremenu, ali i to sam uspješno obavio.

Nakon neka dva tjedna računalo je, oslobođeno plaćanja carinskih pristojbi, sretno stiglo u stan. Knjiga je napisana i tiskana⁴⁵ 1989. g. Od nekih studenata poslijediplomskog studija FOI, koji su došli iz Makedonije, doznao sam da je dospjela i u knjižnicu grada Ohrida.

Međutim, priči tu nije kraj. Naime, otprilike tri godine

⁴⁵ U smislu obuhvata i izlaganja materijala jednako je dobra i danas. Štoviše, koliko je autoru poznato, to je još uvijek jedina knjiga te vrste u Lijepoj Našoj i šire.

nakon izlaska knjige iz tiska, moglo je biti rano proljeće, kod varaždinskog autobusnog kolodvora sreo sam tadašnjeg upravnika (voditelja) varaždinske carinske ispostave, koji je bio dobro upoznat sa cijelom pričom oko računala. Lijepo smo se pozdravili i popričali, i na carinikovo pitanje što je i kako dalje bilo s računalom, ja sam se, davno zaboravivši na spomenutu kaznenu odredbu o neovlaštenom korištenju računala, pohvalio da sam na njemu napisao i prelomio knjigu, koja je već neko vrijeme u knjižarama,...

Nakon nekoliko mjeseci, od koprivničkog općinskog suda dobio sam poziv po kojem se određenog datuma imam pojaviti pred njim, jer sam prijavljen za neovlašteno korištenje tuđeg računala, uvezenog uz povlasticu oslobođenja od carine, što je kažnjivo „po tom i tom zakonu“.

Rečenog datuma pristupio sam sudu, gdje me je ispitao jedan mlađi sudac. Ja sam „krivnju“, tj. da sam inkriminirano računalo koristio za svoje potrebne, suprotno izričitoj zakonskoj zabrani, uredno priznao. Za razliku od policajaca i carinika na granici i varaždinskoj carinskoj ispostavi, sudac je bio vrlo ljubazan i kao da mu je bilo neugodno što smo se obojica, svaki u svojoj ulozi, našli u tako, bar za mene, grotesknoj situaciji.

Sukladno sudskom rješenju prekršajno sam osuđen na plaćanje određene novčane kazne. Na samu presudu, kao ni na iznos novčane kazne, nisam se žalio te sam istu uredno, u zakonski propisanom roku, uplatio u Državni proračun Republike Hrvatske. Možda sam kao žalbeni argument, sebi u korist, mogao, prafrazirajući čuvenu izreku Ostapa Bendera iz romana Zlatno tele, Iljfa i Petrova: '(Ako su) ideje naše, (onda je) benzin vaš!',

preoblikovanu u shemu logičke implikacije, iznijeti činjenicu da sam, istina, računalo zloupotrijebio u idejnom smislu, na njemu pišući i prelamajući knjigu, ali da sam, ipak, krajnju štetu, tj. otisnutu knjigu, otisnuo na računalo koje sam ja platio, na svome papiru i svome pisaču, tj. da je, u krajnjoj instanci, materijalna šteta, iliti "benzin", također išla na moj račun. Međutim, nisam baš bio siguran kako bi se to suda dojmilo pa sam od toga odustao⁴⁶.

Apstrahiramo li od svih postranih događanja oko znanosti i znanstvenika, poput navedenih, ali nikako i jedinih, zaključit ćemo da svaka ozbiljna znanost, da bi se uopće razumjela, valjano koristila i eventualno razvijala, od pojedinaca koji se njome kane baviti zahtijeva prekoračenje određenog misaonog „praga“, čiji vrhunac nije čak ni sposobnost rješavanja problema, već postavljanje novih.

Tijekom svoga razvoja, društvene, a humanističke znanosti još i više, na neki su način bivale pošteđene primjene suvremenih znanstvenih teorija, ne samo iz već neko vrijeme prilično bogate riznice umjetne inteligencije, kako osjetilne, tako i kognitivne, već i egzaktnih metoda kao takvih.

Tamo gdje je i bilo pokušaja primjene znanstvenih metoda, to nije uvijek izlazilo na dobro. Primjerice, na jednoj međunarodnoj konferenciji autor je nazočio izlaganju tijekom kojega je izložen model rasta cijena u kojem su one rasle eksponencijalno, a ne „eksponencijalno“, kao u nedavnim dnevnim izvješćima o rastu broja oboljelih od COVID-a, uz multiplikativni korektivni faktor blizak jedinici, što je neobično iz dva razloga. Prvo, sam model eksponencijalnog rasta cijena vrlo je upitan i sam po sebi. Nadalje,

⁴⁶ Možda bih tada u državni proračun bio morao uliti još malo više „benzina“..

ako je on uistinu takav, onda multiplikativni korektivni faktor blizak jedinici za njegovo ponašanje ne znači baš ništa. Na pitanje izlagatelju rada da model objasni, odgovor je bio samo da su ga sročili ekonomisti?!

Takvi primjeri sreću se posvuda, uključujući i doktorske disertacije. Kada je već o njima riječ, a isto se može reći i za nemali broj znanstvenih radova iz područja društvenih znanosti, uključujući i humanistiku, pretežita „znanstvena metoda“ koja se u njima koristi za postizanje znanstvenih rezultata jest statistička metoda, što samo po sebi nije sporno, jer statistika, primjerice, igra važnu ulogu u kontekstu metoda strojnog učenja općenito, i posebice tzv. *dubokog učenja*. Stvar je u tome da se na probleme koji se rješavaju često primjenjuju neprimjerene statističke metode, na premalim, loše strukturiranim skupovima podataka i bez planiranja statističkog eksperimenta.

Nadalje, mnoge analize, često ekonomske, često političke, počesto u prostoru javnih medija, izlažu se „tautologično“. Naime, analitičar najčešće polazi od prikrivene ekvivalencije tvrdnji koju želi dokazati, što onda nije nikakav problem, osim u slučaju da u međuvremenu ne učini kakvu logičku pogrešku, neovisnu o predmetu i sadržaju „analize“, jer je od nje i pošao (sic!), a međukoraci do nje zapravo su samo šareni „šušur“.

Drugi primjer istupi su sportskih trenera, ponekad i u ulozi više-manje samoproglašanih „usrećitelja nacije“, najčešće u ekipnim sportovima, posebice pred važne utakmice, u medijima poput TV-a, popraćenih najavama tipa „razmišljanja stratega“, gdje narativ teče otprilike ovako: „Ako mi „budemo svoji“, „skupimo glave“, „ostavimo srce na travnjaku“, „...“, „onda ćemo mi pobijediti“.

Dobri „stratezi“, logičkim rječnikom rečeno, zapravo iskazuju *abduktivne*⁴⁷ tvrdnje čije premise (pretpostavke), čak i ako su istinite, općenito nisu ni nužne, a ni dovoljne za istinitost zaključka („mi ćemo pobijediti“). Tu ne pomaže ni *obrat po kontrapoziciji*⁴⁸, koji je također abduktivna tvrdnja⁴⁹, pa tim više iznenađuje značaj koji se u medijima, s obzirom na dodijeljenu minutažu, pridaje takvim izjavama. Međutim, da budemo iskreni, i to je bolje od „tautologičarenja“ ranije spomenutih „analitičara“.

Svim tim „analitičarima“ i „stratezima“ ne bi bilo zgorega, recimo, upoznati metodu „dokaza i opovrgavanja“ Imre Lakatosa (Lakatos, Worrall i Zahar, 2015)⁵⁰, pa bi, pored statističkih metoda, i ona, i općenito širi sklop logičkih metoda i logičke argumentacije, trebali ući u riznicu „metodologije znanstvenog rada“, što je kolegij koji se često sreće, ako ne drugdje, a onda na našim brojnim doktorskim studijima.

Iz prethodno rečenoga jasno je da bi znanstvenike u području društvenih znanosti, humanistike, ali i šire (medicina, pravo,...) trebalo osnažiti valjanim znanjima i metodama egzaktnih znanosti, u mjeri i na način koji će im ta znanja omogućiti usvojiti i valjano koristiti. Jasno je također da neće svakome znanstveniku ni stručnjaku u svakom trenutku trebati sva ili većina znanja iz

⁴⁷ Vidjeti, primjerice, (Schurz, 2007).

⁴⁸ Tvrdnja $A \rightarrow B$ ekvivalentna je tvrdnji $\neg B \rightarrow \neg A$. Riječima, ako A povlači B , onda ne B povlači ne A . *Obrat po kontrapoziciji* tvrdnje *Ako kiša pada, ulice su mokre* jest tvrdnja *Ako ulice nisu mokre, onda kiša ne pada*, ili, *Ako su ulice suhe, onda kiša ne pada*.

⁴⁹ U slobodnoj interpretaciji, u slučaju primjera s trenerima: Ako i „jesmo pobijedili“, to ne znači da smo „skupili glave“, „ostavili srce na travnjaku“, „... Naime, moglo se dogoditi da si protivnički igrač nesrećom zabije autogol,...

⁵⁰ Usput rečeno, knjiga je prevedena na više od 15 jezika, uključujući i hrvatski.

riznice znanja i znanstvenih metoda umjetne inteligencije (i ne samo nje). Međutim, za „snalaženje u prostoru“, dobro je imati širi uvid u njih. Jedan takav dobar uvid pruža netom tiskana knjiga *Artificial Intelligence in 21st Century*, izdavača Mercury Learning and Information, treće izdanje, 2022. g. Sažetim izlaganjem nekih znanstvenih teorija, metoda i alata koje ona (i ne samo ona) zbirno prikazuje pozabavit ćemo se kasnije, a dalje nastavljamo sa „studijama slučaja“ njihove primjene, u rasponu od osnaživanja samog znanstvenog radnika i stručnjaka kao takvog, pa do primjena u rješavanju određenih tipova znanstvenih problema. Doseg tih izlaganja bit će daleko od potpunog⁵¹. Ipak, nadamo se da će biti dostatno ilustrativan i da će čitatelja potaknuti na daljnje samostalno istraživanje specifičnih okružja i alata za svoje potrebe.

Mentalne mape

Gavni poslovi znanstvenika jesu znanstvena istraživanja te pisanje i publiciranje znanstvenih radova. Malo je radova, barem u današnje vrijeme, koji su rezultat iznenadnog „bljeska svjetlosti u glavi“ (kao u slučaju Nikole Tesle) ili „pada jabuke na glavu“ (kao u slučaju Isaaca Newtona). Pretežiti dio suvremene produkcije znanstvenih radova daleko je od romantičnih ili čak dramatskih⁵² događanja te pored određene mjere nadahnuća zahtijeva dugotrajan i nadasve organiziran rad. Nastankom programa za obradu teksta (Word Perfect, MS Word, OpenOffice Writer,...) samoorganizacija znanstvenika za potrebe znanstvenog

⁵¹ Što opravdava naslov poglavlja.

⁵² Iako postoje značajne iznimke, kao u slučaju stvaranja cjepiva protiv Covida ili u slučaju Grigorija Perelmana, ruskog matematičara koji je dokazao tzv. *Poincareovu hipotezu*, koja je bila otvorena više od sto godina.

rada dobila je nužnu, ali ne i dovoljnu potporu. Razvojem alata za tehničko crtanje kao što je MS Visio i njemu slični, znanstvenici su dobili neku vrstu potpora za grafičku prezentaciju svojih ideja i zamisli te za strukturiranje svojih radova.


Ipak, tek su specijalizirana okružja za crtanje (oblikovanje, strukturiranje,...) mentalnih mapa, kao što su XMind, MindMeister, MindManager,..., osigurala zadovoljavajući strukturirani pristup modeliranju misaonih i organizacijskih procesa za potrebe znanstvenog rada, i ne samo njega.

Nakon kratkog izlaganja teme mentalnih mapa reći ćemo nešto više o projektu istraživanja čuvene knjige *Umijeće ratovanja*, kineskog autora Sun Tzua njihovom uporabom. Samo istraživanje izloženo je u nedavno tiskanoj knjizi (Boas i sur., 2022).

Utemeljiteljem mentalnih mapa u suvremenom smislu smatra se engleski psiholog Tony Buzan, iako one dokumentirano datiraju iz antičkog doba. J. M. Guerrero u (Guerrero 2022, str. 5) izlaže prikaz tzv. „skale bića“ starogrčkog filozofa Porfirija u njegovu *Uvodu (Isagoge)* u Aristotelove kategorije, djela nastalog u 3. stoljeću prije N. E., prema kasnijem Boetievu prijevodu na latinski jezik. Slika 4-5 prikazuje Porfirijevo stablo.

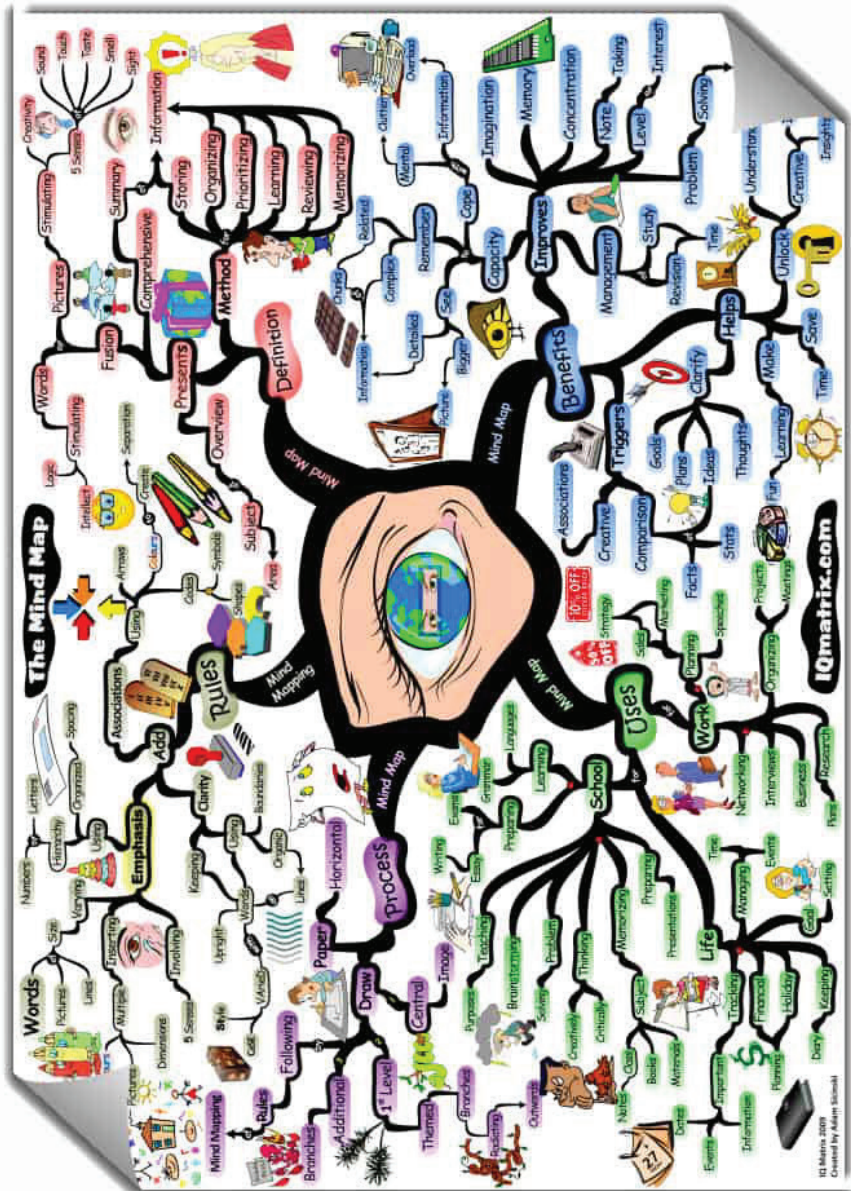
U svojoj knjizi (Buzan, 2012) Tony Buzan navodi nekoliko temeljnih stvari u kojima mentalne mape mogu pomoći. To su: *planiranje, komuniciranje, veća kreativnost, štednja vremena, rješavanje problema, koncentracija, organiziranje i verificiranje razmišljanja, bolje pamćenje, brže i učinkovitije učenje, cjelovit uvid u stvari, smanjenje stresa.*

IN PORPHYRIUM DIALOGUS I.



SLIKA 4-5: Prikaz Porfirijeva stabla kao primjera mentalne mape (Guerrero 2022, str. 5).

Iz popisa je jasno da Buzan nije na umu imao samo korištenje mentalnih mapa za potrebe znanstvenih istraživanja i organiziranja znanstvenog rada, kako pojedinaca, tako i grupa znanstvenika, već ih je vidio u širem životnom kontekstu. U njihovu pohvalu Buzan navodi i znamenite znanstvenike i umjetnike prošlih vremena koji su za potrebe svojih znanstvenih istraživanja i stvaranja umjetničkih djela koristili mentalne mape.



SLIKA 4-6: Mentalna mapa s prikazom strukturiranja mentalnih mapa.

IZVOR: <https://mindmapsunleashed.com/10-really-cool-mind-mapping-examples-you-will-learn-from>

Među njima su Leonardo da Vinci, Michelangelo Buonarroti, Isaac Newton, Albert Einstein, Marie Curie, i mnogi drugi.

Sam proces stvaranja mentalnih mapa Buzan propisuje u sedam koraka. Oni su, uz nešto problematiziranja u konceptualnom dijelu, primjerice u (Guerrero 2022, str. 31), u izvedbenom uglavnom prihvaćeni, naravno uz različita proširenja paradigme tijekom vremena.

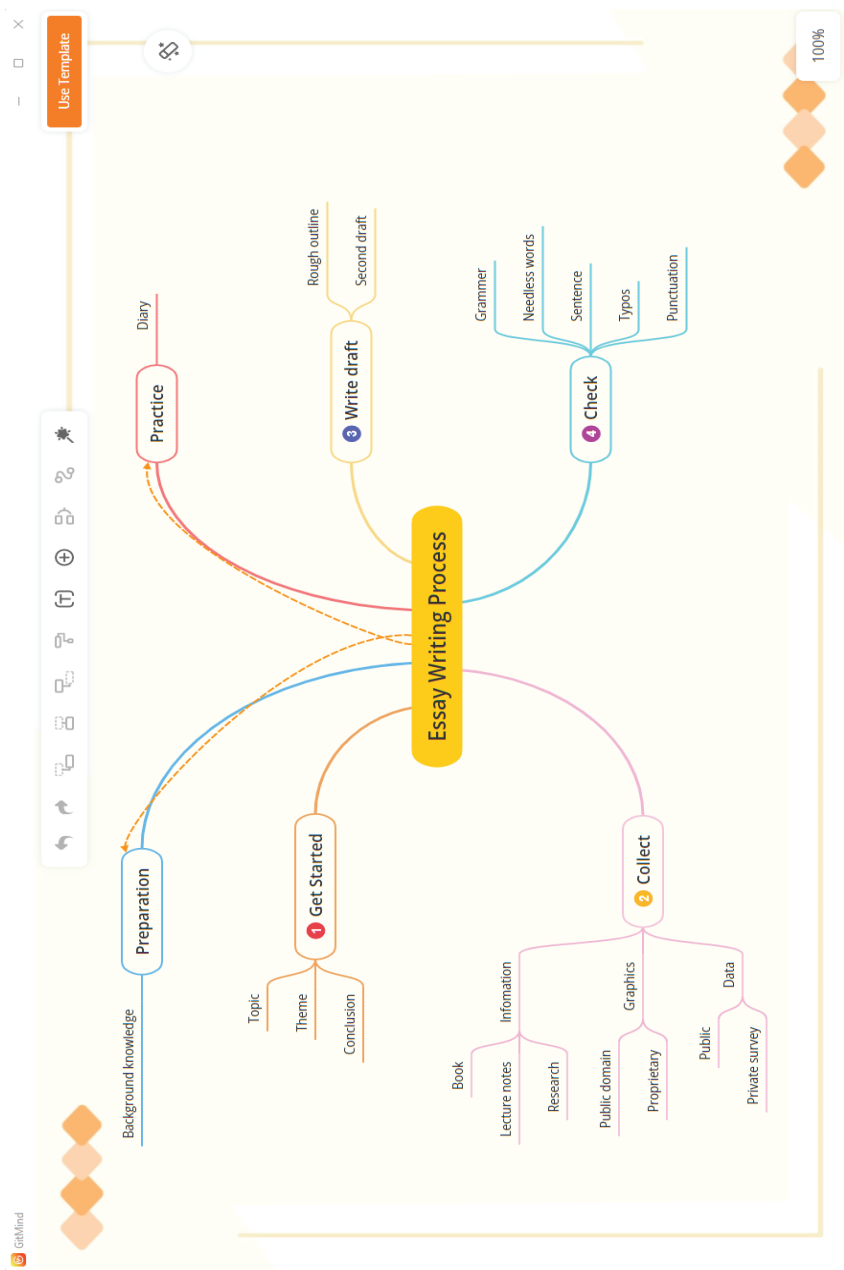
Umjesto da izlažemo Buzanova i druga pravila strukturiranja mentalnih mapa, ovdje prikazujemo jednu (Slika 4-6) koja se upravo time bavi!

Vidljivo je da mapa ima strukturu stiliziranog (kvazi) stabla, s glavnim čvorom MindMap/MindMapping i pet glavnih podstabala (*Definition, Rules, Process, Uses, Benefits*). Zatim, čvorovi svakog od nabrojanih podstabala obojani su drugom bojom. Nadalje, većini krajnjih čvorova (i ponekim granama) pridružene su sličice (popularne „ikone“) koje ih dodatno ilustriraju.

Također, svaka grana, ako se čita od naslovnog čvora odgovarajućeg podstabla do nekoga od završnih čvorova (listova), pobliže opisuje neko svojstvo mentalnih mapa. Tako, primjerice, jedna putanja podstabla *Benefits (Dobrobiti)* kazuje da mentalna mapa pomaže učenje činiti zabavnim. Druga kazuje da mentalna mapa unapređuje/pospješuje rješavanje problema, itd.

Elementi definicije mentalnih mapa očitavaju se iz podstabla *Definition*. Tako jedna putanja kaže da mentalna mapa predstavlja metodu pohranjivanja, organiziranja, pamćenja, vrednovanja,... informacija.

Neke od alata i okružja za razvoj mentalnih mapa već smo naveli (XMind, MindMeister, MindManager). Puna verzija



SLIKA 4-7: Obrazac mentalne mape procesa pisanja eseja u programu GitMind.

svakoga od njih je komercijalni softver. Međutim, ima i besplatnih, djelomično ili u cijelosti⁵³. Neki su samostojeći, a neki *online*. Za većinu potreba znanstvenika dobre su i besplatne izvedbe.

Većina izvedbi strukturno je slična, nudeći razvoj mentalnih mapa „od početka“, ili korištenjem unaprijed sročениh obrazaca, različite strukture (hijerarhijske, stablaste,...), različite namjene (obrazovanje, marketing, planiranje, inženjerstvo,...), različitih vizualnih iskaza (paleta boja, izbor ikona,...), itd. Posve besplatan, a uistinu vrijedan pažnje, GitMind (Slika 4-7), pored klasičnih mentalnih mapa nudi i klasične obrasce dijagrama toka, UML-dijagrama, itd.

Za kraj ove teme dajemo kratak prikaz istraživanja *logike* teksta *Umijeće ratovanja* starokineskog autora Sun Tzua, metodom mentalnih mapa, izloženog u ranije spomenutoj knjizi (Boas i sur., 2022).

Ponajprije treba naglasiti interdisciplinarnost projekta, s obzirom na kompetencije članova projektnog tima.

Peter van Emde Boas⁵⁴ rođen je i odrastao u Amsterdamu. Po temeljnom obrazovanju je matematičar, specijaliziran za teoriju složenosti algoritama, logičku semantiku, teoriju baza podataka, simboličku računalnu lingvistiku, teoriju igara i umjetnu inteligenciju. U području struktura podataka poznat je kao pronalazač tipa stabala u smislu apstraktne strukture podataka, koja su danas poznata pod njegovim imenom. Nakon umirovljenja, 2009. g., aktivno djeluje na Institutu za logiku, jezik i računalstvo, u čijem je osnivanju svojevremeno sudjelovao

⁵³ Vidjeti, primjerice, poveznicu <https://gitmind.com/free-mind-map-software.html>.

⁵⁴ Podaci su preuzeti s poveznice <https://link.springer.com/book/10.1007/978-981-19-6250-9#about-authors>.

te u zajedničkom Amsterdamsko-kineskom centru za logiku pri Sveučilištu Tsinghua u Kini. Djelovanjem kroz navedene institucije bavi se vezama između klasične kineske strategije (političke, vojne, *op. a.*), teorije igara i logike.

Ghica van Emde Boas rođena je kao Hendrica Lubsen u Amsterdamu, Nizozemska. Kao matematičarka po obrazovanju radila je 30 godina za IBM u Nizozemskoj. Bavila se problemima razvoja i implementacije ranih sustava za upravljanje relacijskim bazama podataka. Trenutačno je u mirovini.

Kaibo Xie rođen je u Hangzhouu u Kini. Završio je studij filozofije na Školi humanističkih znanosti Sveučilišta Zhejiang i magistarski studij logike na Institutu za logiku, jezik i računalstvo Sveučilišta u Amsterdamu. Njegova doktorska disertacija, *Where Causality, Conditionals and Epistemology meet; A Logical Inquiry*, bavi se filozofskim problemima na raskrižju proučavanja (logičkih, jezičnih) kondicionala, kauzaliteta i epistemologije i istraživanja logičkih pristupa tim problemima. Još od preddiplomskog studija zanimaju ga kineski klasici i logika. Iako su mu publikacije uglavnom usredotočene na filozofsku logiku, on također istražuje područje dodira logika i antičke klasike. Trenutno radi kao post-doktorand na Odsjeku za filozofiju Sveučilišta Tsinghua.

Bonan Zhao doktorandica je na Sveučilištu u Edinburghu, Škotska. Na Institutu za logiku, jezik i računalstvo na Sveučilištu u Amsterdamu stekla je magisterij u području logike, a studij filozofije završila je na Sveučilištu Tsinghua, Peking, Kina. Njezino trenutno istraživanje usmjereno je na računalne modele ljudskog kauzalnog zaključivanja.

Ovako relativno široko predstavljanje autora nije svrha

samome sebi. Ono za cilj ima maksimalno naglasiti nužnost suradnje znanstvenika i stručnjaka različitih profila, naglašeno specijaliziranih u svom užem području znanstvenog i stručnog djelovanja, ali i sa solidnim uvidom u druga područja, vezana uz istraživački problem koji zajedno istražuju. To se zacijelo odnosi i na istraživanja u području digitalne humanistike. Na „prosvjetnim vlastima“ je da to osiguraju.

U slučaju istraživanja koje je predmet knjige, prepričano prema (Boas i sur., 2022, str. x), uloge sudionika bile su sljedeće:

Uloge autora u istraživanju *Umijeća ratovanja*

Peter je glavni znanstvenik koji je doprinio svojim znanjem o matematici, teorijskoj informatici, logici i teoriji igara.

Bonan je pridonijela ideji traženja obrazaca u tekstu Sun Tzua, a ona ih je i opisala. Također je izradila kineske verzije mentalnih mapa.

Kaibo je odgovoran za teme vezane uz drevnu kinesku logiku i lingvistiku. Proučavao je posebne kineske znakove i posebne jezične konstrukcije u kojima se koriste. Štoviše, pridonio je studijom o proturječjima i njihovom značenju u Sun Tzuovo vrijeme.

S poznavanjem klasičnog kineskog **Bonan** i **Kaiboa** otkrivene su posebne jezične konstrukcije i učinjeni bolji prijevodi.

Ideja o izradi mentalnih mapa potekla je od **Ghice**. Ona je također izradila LATEX-ove datoteke za tekst knjige i alate za stvaranje jedinstvenog izgleda teksta i mentalnih mapa u svim poglavljima.

Izvorni cilj istraživanja bio je istražiti veze između ideja Sun Tzua i suvremene logike, posebice aspekata povezanih s teorijom igara i teorijom uma. Prvi rezultati istraživanja pokazali su da


Umijeće ratovanja ima čvrstu *logičku strukturu*, i kao takvo, po mišljenju autora, predstavlja *logički sustav*.

Pojedinačne mentalne mape ovdje ne navodimo. Moguće ih je vidjeti na poveznici <https://suntzu.squaringthecircles.com/chapterN.php?chapter=1&pass=3>.

Puno korisnih informacija o mentalnim mapama i njihovoj primjeni čitatelj će naći na poveznici <https://mindmappingsoftwareblog.com/>.

Stilometrija

Predstavu *Stilske vježbe*, po tekstu Raymonda Queneaua, (Queneau, 2008), u hrvatskom prijevodu i maestralnoj izvedbi Lele Margitić i Pere Kvrgića, autor je prvi put imao čast pogledati u Teatru &TD, u sklopu zagrebačkog Studentskog centra, kasnih osamdesetih prošlog stoljeća, a drugi put četrdesetak godina kasnije, na sceni varaždinskog HNK. Tko nije, jedna od predstava dostupna je na kanalu YouTube. Lako će je pronaći.



SLIKA 4-8: Plakat predstave *Stilske vježbe*.

Za one koji knjigu nisu čitali ili predstavu gledali, u prvom monologu Lela gledatelja uvodi u kratku, bizarnu priču⁵⁵, o ponašanju jednog mlađeg čovjeka u tramvaju broj 11, na liniji od Črnomerca do Dubrave.

Stilske vježbe – osnovna tema

Za vrijeme najveće gužve u tramvaju broj 11, jedan tip od kojih 26 godina, s onim ludim šešišom – konopčić umjesto vrpce – bjesni na jednoga susjeda. Predbacuje mu da ga gurne svaki put kad netko prođe. Uto primijeti jedno slobodno mjesto – zaleti se i zauzme ga. Dva sata poslije sretnemo ga opet pred glavnom poštom. U Jurišićevoj. Sad je s nekim drugim koji mu otprilike kaže: “Moraš prišiti još jedan gumb na kaput.” Pokazuje mu gdje (pokazuje na sebi) i zašto. (nakon stanke) Eto!

Nakon toga, Lela i Pero naizmjenice, a ponekad i zajedno, variraju osnovnu temu. Izvornik sadrži ukupno 99 varijacija. Za čitatelja autor je izabrao dvije varijacije, jednu „zagrebačku“ i jednu „parišku“.

Stilske vježbe – (Quenau, 2008, str. 148)

Znaš srce, ja sam ti danas bila na šetnjici i onda sam ti se jaako umorila pa sam se sjela na tramvaj. I tamo sam ti vidjela jednog kuštravog dečka sa slatkim dugim vratićem i šeširićem na onoj smiješnoj glavici. A kraj njega ti je bio jedan mali slatki debeli čičica. Ali onaj dečko je bio nešto zločest, pa ga je čičica počeo ovaaako gledati. A mali zločko ti se naljuti, okrene čičici riticu i sjedne na jednu stolicu.

I znaš srce, poslije ti ja idem na poštu i opet ti vidim onog malog zločka. I s njim ti je bio jedan drugi slatki mali. I oni dva su ti se nešto straaašno ozbiljno razgovarali o nekom gumbiću.

⁵⁵ Uklopljenu u zagrebačke toponime. Za potrebe predstave preveo Tonko Maroević. Prilagodio Tomislav Radić.

Gornja vježba izvorno nije naslovljena. Naslov **MILOSTIVICA** bio bi primjeren.

Stilske vježbe – PRIPROSTA

Neš iza podnea uspio ti se ja ukrcau u Esicu. Uđem ti daklem ja, kupim, narafski kartu, jelde, kad enotigana, odma uškicam jednog što glumi frajera, nekog uštogljenog dupeglafca, za čiji bi vrat čovjek reko da je teleskop, a bio ti je ovio neku špagu oko klobučine. Nisam ti ga baš bleno unjega, jerbo nevolim dupeglafce, kad enotigana, počme dotični prekoravat sebi najbližeg putnika. Slušajte vi, obrecno tise on na dotičnog, mogao bi vi malo pripaziti, nastavi on, razumieš ti mene, čovjek bi pomisljio, cmizdruljio ti on, da vi to činite namjerice, trtljo ti on tako, to, mislim, veli, da mi stalno gazte po nogama, govori. A ondak, jelte, onako uznosito, otperja sjesti.

Vraćam tise ja poslie preko Rimskog kadli spazim dotičnog kako laprda s jednim istotakvim dupeglafcem. Slušaj, veli njemu taj drugi, morobi, govorioje, prišiti još jen gumbek, produži dotični, jelda, na taj tvoj iberciger, zaključti on.

Jedno od globalnih stilskih obilježja teksta jest i stil kao vremenska odrednica. Ilustrira to sljedeći tekst (Göthe,...), u rubrici *Smešice* (anegdote, smiješne zgode,...), u časopisu Danica Ilirska, Tečaj VII., br. 13., 1841., str. 52.

Gusto posjetjen od mnogo prihodnikah bojao se je Göthe najviše od englezkih putnikah, znajući da će svaka reč, koju on izusti, biti zabilježena i u javnih listovih naštampana. Porad toga, kad mu se neki Englez u pohod pojavi, preduzeo si je on, da š njime što manje razgovara, i to samo o nevažnih stvari. Unidje Englez, a Göthe ga pozdravi bez išta reči; Englez se nakloni i muči. Göthe pokaže mu rukom na jednu stolicu, i Englez sedne bez da bi usta otvorio nadajući se da će Göthe razgovor zametnuti. Tako prodje pet minutah u dubokom mućanju; tada Göthe ustajući dade poznati svojemu šutećemu gostu svēršetak ovoga čudnovatoga pohoda. Prateć vëndar Engleza kroz prednju sobu, požalio ga je Göthe, ter pokazujuć mu jedan mramorni kip, reče: »Walter Scott« — »Umro je,« odgovori Englez,« i tako sverši se njegov pohod.

Teško da bismo tekst *Smešica* svrstali pod stilska obilježja suvremenih autora. Razlog su arhaičan vokabular, nestandardna množina imenica, *dj* umjesto *đ*, mjestimice zapis imenice u ekavici (*reč* umjesto *riječ*), itd.

S vremenskim atribucijama tekstova treba biti posebno oprezan. Autori kasnijeg razdoblja, ako iz bilo kojeg razloga baš žele, relativno lako, bar na prvi pogled, mogu *oponašati* stil pisanja autora ranijeg razdoblja. Problemima *oponašanja* stila pisanja, odnosno njegova *maskiranja* ili *zamagljivanja* bavi se grana stilometrije, u engleskoj terminologiji znana kao *adversarial stylometry*⁵⁶. Kao primjer, kad smo već kod *stilskih vježbi*, na sljedećoj stranici dajemo još jednu (Queneau, 2008, str. 137) koja ilustrira oponašanje stila pisanja prošlih vremena.

⁵⁶ Riječ *adversarial* u engleskom jeziku ima više značenja, poput *kontradiktoran*, *neprijateljski*,...Ovdje je ne prevodimo kako ne bismo opterećivali buduću stilometrijsku terminologiju u kontekstu hrvatskog jezika.

Stilske vježbe – (Queenau, 2008, str. 137)

Dike ter hvaljenja sad ću govoriti
ter malo starpljenja vas hoću moliti:
Suncu srid nebesa visoko biše stan
a u kolih spleša – množina ljudi sta.
I sred te čride kad gladan se vozeći
sritnem ti Vlaha tad, koj klobuk noseći,
konopac držaše umisto kurdele
(I s dušom psovaše) a imaše vele
i dug i visok vrat – Čelave ti dice
spominjaše on rad, i k tomu divice
jednom gosparu sa bilim očima
i ne odveć staru, jer da ga prižima
baš po gnjatu kad puk nasrne
o drugom satu, kad s posla se vrne.
Ali svađa presta jerbo Vlah uteče
put praznoga mjesta sav blažen priteče.
Malo iza tega, vridno je spomina
vidju opet njega s jednim iz Knina;
stojeći na putu ovaj mu savjet da:
puce na kaputu digni za parst ili dva.

Puno ne razmišljajući, sasvim površno i ne znajući o čemu je riječ, autor bi rekao da bi tekst mogao datirati iz Hektorovićeve vremena.

Kad smo već kod imitiranja stila književnog teksta, recimo da u *igru imitiranja*, u puno širem kontekstu, spada i tzv. *Turingov test*. Cilj mu je da računalo obmane čovjeka u dijalogu „o svemu i svačemu“, što bi trebalo biti dokazom ljudske inteligencije samoga računala. Za ozbiljno upoznavanje s problemom Turingova testa i raspri koje se oko njega vode, vidjeti, primjerice, (Epstein

i sur., 2008). Autor se priklanja tezi da samo organska evolucija može dovesti do razvoja inteligencije poput ljudske (i ne samo), a pogotovo do *svijesti o sebi*, unatoč nedavnoj buci u medijima oko toga da je u nekim eksperimentima računalo tu svijest iskazalo. Da se čak i ta svijest može u dobroj mjeri *imitirati*, nije sporno. Za prvu ruku bilo bi dovoljno u otvorenu ontologiju, poput ontologije Gellish, opisane u (Renssen, 2015), ugraditi tzv. *aksiome znanja* iz teorije rezoniranja o znanju u višeagentnim sustavima (vidjeti, primjerice, (Fagin i sur., 2004)), posebice aksiome pozitivne

$(K_i\varphi \rightarrow K_iK_i\varphi)^{57}$, odnosno negativne

$(\neg K_i\varphi \rightarrow K_i\neg K_i\varphi)^{58}$ introspekcije.

Želi li se čitatelj poigrati modeliranjem znanja u više-agentnim sustavima, preporučamo mu da se obrati članku (Schwarzentruber, 2018), gdje će naći i poveznicu na odgovarajuću aplikaciju. Naslovi prijevoda stilskih vježbi u izvornom okružju otkrivaju da su stilske razlike između njih u suštini semantičkog karaktera, što dodatno daje značaj takvim metodama u sklopu stilometrijskih istraživanja.

U *stilskim vježbama* različite vrste okušali su se i drugi autori, često potaknuti Queneauovima. Tako Matt Madden, u (Madden, 2005), kroz kratke stripove varira situaciju u kojoj se glavni junak, ili više njih, kao raspolučeno biće, različite dobi, spola i „vrste“ (papiga, robot,...) u svom „svakodnevnom okružju“, pomalo rastresen, raspituje za točno vrijeme, a nakon toga se nađe u situaciji da sam sebe pita što je zapravo tražio u prostoru u kojem

⁵⁷ Ako agent K_i zna „znanje“ (formulu) φ , onda on zna da zna φ .

⁵⁸ Ako agent K_i ne zna „znanje“ (formulu) φ , onda on zna da ne zna φ .

se nalazi (ispred otvorenog hladnjaka, u tučnjavi na ulici, itd.).

Da čitatelji ne bi ostali uvjerenja da su samo lijepe umjetnosti kao književnost i osobito glazba, sklone varijacijama na izabrane teme. spomenimo i knjigu (Ording, 2021), u kojoj autor izlaže 99 varijacija dokaza⁵⁹ sljedećeg teorema:

Ako je $x^3 - 6x^2 + 11x - 6 = 2x - 2$, onda je $x = 1$ ili $x = 4$.

Stilometrijska obilježja teksta i stilometrijske metode

Prema (Lagutina i sur., 2019), *stilometrija je dio računalne lingvistike koja se bavi kvantitativnim vrednovanjem obilježja teksta prirodnog jezika.*

Predmet njezina izučavanja temeljno je *stil izražavanja svojstven pojedinačnom autoru*⁶⁰. Razvoj stilometrije iznjedrio je, prema (Neal i sur., 2018) već bliže tisuću stilometrijskih obilježja, u rasponu od *najniže sintaktičke* do *najviše semantičke* razine. Sam *stil* ukupnost je tih obilježja slijedom kojih ljudski mozak stvara *semantički model/dojam* teksta.

Najniža razina stilometrijskih obilježja teksta isti shvaća kao niz sintaktičkih konstrukata nad odgovarajućom abecedom/alfabetom. Čest konstrukt je tzv. *N-gram*, definiran kao neprekinut niz od N znakova. U istraživanjima i eksperimentima često se razmatraju N-grami različitih duljina, ovisno o cilju istraživanja. Prednost im je da ih je moguće lako ekstrahirati, primje-

⁵⁹ Neki među njima su više „dokazi“, negoli dokazi, ali u kontekstu *stilskih vježbi* posve su u redu. Uostalom neka čitatelj čitajući knjigu sam prosudi.

⁶⁰ Poznat i kao *idiolekt*. Za više detalja vidjeti <https://hr.wikipedia.org/wiki/Idiolekt>.

rice, metodom tzv. *regularnih izraza*⁶¹, a nedostatak da troše puno memorijskog prostora računala i povećavaju složenost pripadajućih algoritama. Često se koriste za potrebe predobrade teksta (uklanjanje viška razmaka/bjelina, segmentiranje teksta, niveliranje velikih i malih slova,...).

Razina iznad bavi se riječima, kako onima koje *nose smisao* (imenice, glagoli, pridjevi i prilozi), tako i onima koje se svrstava u tzv. *funkcionalne riječi* (članovi, zamjenice⁶², prijedlozi, veznici i neki pomoćni glagoli). Među statističkim parametrima koji se mjere su duljina riječi, prosječna duljina riječi skupa riječi, N-grami riječi, itd. U predobradi teksta i ovdje jako pomažu regularni izrazi.

Na gornjoj razini analizira se rečenična struktura. To uključuje parametre poput frekvencije znakova puntuacije, duljine rečenice, prosječne duljine rečenica na skupu riječi, kao i frekvencije funkcionalnih riječi.

U (Lagutina i sur., 2019) autori konstatiraju da je semantička obilježja teksta koja odražavaju značenje riječi, izraza ili rečenica, teško utvrditi i formalizirati, da netom spomenute strukturne značajke iskazuju bitne razlike u tekstovima različitih žanrova dokumenata te su stoga izrazito mjerodavne za njihovo proučavanje.

S potonjim se lako složiti, uz napomenu da i semantička analiza teksta u zadnje vrijeme bilježi znatan napredak. Jedan

⁶¹ Izravno, u vidu *jezičnih konstrukata*, ili u vidu *modula, biblioteka, paketa*,... ugrađeni su u mnoge suvremene programske jezike, kako proceduralne (C#, Java, JavaScript, R, Python,...), tako i deklarativne (Prolog,...), skriptne (VB, NET) te jezike za oblikovanje Web-stranica (HTML,PHP). Regularni izrazi predstavljaju dragocjenu metodu sintaktičke obrade/analize teksta i svatko tko se bavi stilometrijom morao bi ih dobro poznavati. Za kratak, ali dobar uvod u regularne izraze, vidjeti, primjerice, (Fitzgerald, 2012).

⁶² Vrednovanje zamjenica u ovom kontekstu donekle je problematično, jer one mogu figurirati kao subjekt i objekt u rečenici.

od djelomice i njoj posvećenih ranijih radova je i (Čubrilo i sur., 2001). Različiti aspekti proučavanja semantike teksta mogu se naći u knjigama poput (Delmonte, 2008), (Bast i sur., 2016b), (Renssen, 2015) te disertaciji (Orešković, 2019).

Među stilometrijskim problemima koji su danas u žiži istraživanja svakako treba naglasiti sljedeće:

- Problem atribucije autorstva teksta u tzv. *zatvorenom skupu autora* koji temeljem određenog broja tekstova poznatih autora nastoji utvrditi stvarnog autora konkretnog teksta među „sumnjivim“ kandidatima.
- Problem atribucije autorstva teksta u tzv. *otvorenom skupu autora* dopušta da „sumnjivi“ autor može biti i netko izvan skupa pretpostavljenih autora.
- Problem verifikacije koji se bavi utvrđivanjem autorstva konkretnog teksta, pod pretpostavkom samo jednog „sumnjivog“ autora.
- Problem profiliranja autora, s obzirom na spol, dob, demografske odrednice, socijalni status, itd.
- Problem utvrđivanja zajedničkog autorstva teksta od strane više autora.
- Problem utvrđivanja plagijata.
- Problem utvrđivanja oponašanja tuđeg stila pisanja.
- Problem analize sentimenta.
- Problem utvrđivanja promjene stila određenog autora tijekom vremena (stilkronometrija).
- Problem utvrđivanja tzv. *lažnih vijesti*.

Na neke od navedenih problema pobliže ćemo se osvrnuti

nešto kasnije. Prije toga osvrnut ćemo se na dio znanstvenih metoda koje stoje na usluzi stilometrijskim istraživanjima. One su izvorno *statističke*, ali im u najnovije vrijeme u pomoć hitaju metode *semantičke analize teksta*, kao i metode tzv. *dubokog učenja* iz riznice metoda učenja uz pomoć neuronskih mreža. O potnijima će još biti govora, a ovdje ukratko izložimo nešto od statističkih metoda prema (Neal i sur., 2018).

Statističke metode na usluzi stilometriji

Kako je već rečeno, broj stilometrijskih obilježja teksta broji njih više od tisuću. Tako velik skup obilježja zahtijeva valjane statističke metode za sve vrste obrade teksta, pa tako i za potrebe stilometrije. Među njima, za prikaz smo odabrali četiri koje su korištene u stilometrijskoj „potjeri“ za stvarnim identitetom spisateljice/spisatelja⁶³ pod pseudonimom Elena Ferrante. Više o samoj potjeri u narednom odjeljku.

Statističke metode/modele/testove, o kojima postoje deseci znanstvenih članaka i obimnih knjiga, izložiti ćemo u minimalnom nužnom opsegu, samo s najnužnijim matematičkim formulama. To su sljedeće metode:

- Analiza glavnih komponenata
- Burrowsov model Delta
- Labbéovska međutekstovna udaljenost
- Burrowsov test Zeta

⁶³ Na kraju potjere, ipak, spisatelja!

Analiza glavnih komponenata (PCA)⁶⁴

Stil pisanja svakog spisatelja rezultat je nebrojenih interakcija između mnogih numerički mjerljivih obilježja teksta, među kojima spisatelj neke koristi s namjerom, dakle svjesno, a neke da to ni sam ne primjećuje. Što je više stilometrijskih obilježja teksta predmet proučavanja, to su izglednije njihove međusobne interakcije koje skrivaju stvarni učinak svakog pojedinačnog obilježja na proučavana svojstva teksta. Ideja metode PCA jest izvorni skup obilježja teksta reducirati na jednak broj iz njih izvedenih, međusobno neovisnih (jezikom statistike rečeno, *nekoreliranih*) svojstava, koja se zatim rangiraju, omogućujući odbacivanje manje važnih (nižeg ranga), smanjujući tako dimenziju izvornog skupa tekstualnih podataka, uz istodobno zadržavanje njegova željenog (proučavanog) informacijskog sadržaja.⁶⁵

Temeljni statistički parametri koje metoda PCA koristi jesu *kovarijanca* i *koeficijent korelacije*⁶⁶.

Kovarijanca dvaju slučajnih varijabli (obilježja proučavanog teksta) poopćenje je varijance slučajne varijable, koja se, kao što znamo, definira kao očekivanje (srednja vrijednost) kvadrata odstupanja njezinih vrijednosti od njezina očekivanja.

⁶⁴ **P**roduct **C**omponent **A**nalysis (PCA). Po autoru, ponajbolja knjiga novijeg vremena na temu stilometrije, (Savoy, 2020), metodu PCA koristi, ali za njezino upoznavanje u kontekstu stilometrije čitatelja upućuje na članak od dvadeset stranica, (Binongo i Smith, 1999), što nam se ipak ne čini najsretnijim rješenjem. I za potrebe primjene metode nužno je njezino određeno razumijevanje.

⁶⁵ Reklo bi se da se radi o dobrom omjeru *cijene i kvalitete*.

⁶⁶ Čitatelj je tijekom svoga školovanja zasigurno već upoznat s tim parametrima, i općenito, elementima statistike.

Formulom rečeno:

$$\sigma = \overline{(X - \bar{X})^2},$$

gdje $\bar{\quad}$ označava očekivanje. Napiše li se varijanca σ kao

$$\sigma = \overline{(X - \bar{X})(X - \bar{X})}.$$

i drugi nastup slučajne varijable X zamijeni slučajnom varijablom Y , nastaje formula za kovarijancu varijabli X i Y , $\sigma = \overline{(X - \bar{X})(Y - \bar{Y})}$.

Formula za varijancu pokazuje da ona raste s rasapom vrijednosti slučajne varijable u odnosu na njezinu srednju vrijednost, dok formula za kovarijancu pokazuje da ona raste ako obje varijable istodobno rastu ili padaju, tj. imaju istu tendenciju promjene. Bilo koje od toga dvoga znači da su one međusobno povezane (korelirane).

Prvi korak primjene metode PCA jest *normalizacija podataka*. Njezina svrha jest sve slučajne varijable u razmatranju svesti na isti raspon vrijednosti. To je nužno jer veći raspon vrijednosti slučajne varijable rezultira većom vrijednošću varijance i time nju čini dominantnom onima s manjim rasponom vrijednosti i time manjom varijancom. Normalizirana slučajna varijabla X definira se formulom:

$$X \rightarrow Z = \frac{X - \bar{X}}{\sqrt{\sigma}}.$$

Sada je

$$\bar{Z} = \overline{\frac{X - \bar{X}}{\sqrt{\sigma}}} = \frac{\bar{X} - \bar{X}}{\sqrt{\sigma}} = \frac{\bar{X} - \bar{X}}{\sqrt{\sigma}} = 0,$$

odnosno

$$\begin{aligned}\sigma(Z) &= \overline{(Z - \bar{Z})^2} = \overline{\left(\frac{X - \bar{X}}{\sqrt{\sigma}} - \left(\frac{X - \bar{X}}{\sqrt{\sigma}} \right) \right)^2} = \overline{\left(\frac{X - \bar{X}}{\sqrt{\sigma}} - \underbrace{\left(\frac{\bar{X} - \bar{X}}{\sqrt{\sigma}} \right)}_0 \right)^2} = \\ &= \overline{\left(\frac{X - \bar{X}}{\sqrt{\sigma}} \right)^2} = \frac{\overline{(X - \bar{X})^2}}{\sigma} = \frac{\sigma}{\sigma} = 1\end{aligned}$$

Želi li se da to bude segment $[0, 1]$, pomoći će zamjena

$$Z = \frac{X - X_{min}}{X_{max} - X_{min}}$$

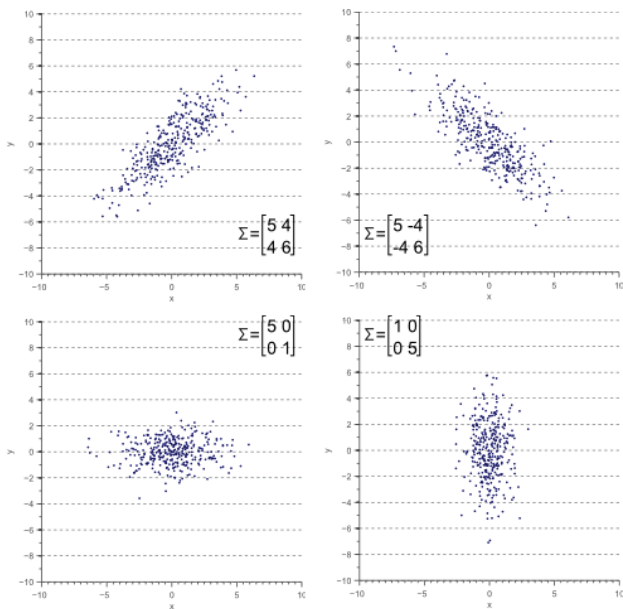
Drugi korak je oblikovanje matrice kovarijanci između svih slučajnih varijabli (tekstnih obilježja) od interesa, uključujući i kovarijancu svake sa samom sobom, što je zapravo varijanca. Nadalje, formula za kovarijancu pokazuje da je to simetrična funkcija, pa će matrica kovarijanci za, recimo, dvije varijable, X_1 i X_2 izgledati ovako:

$$COV = \begin{bmatrix} \sigma(X_1) & Cov(X_1, X_2) \\ Cov(X_1, X_2) & \sigma(X_2) \end{bmatrix}$$

Za opis trećeg koraka trebamo definiciju tzv. *svojstvenog vektora* matrice. To je svaki vektor x (reprezentiran matricom reda $(1 \times n)$, u slučaju matrice COV reda 1×2) za koji je (opet za slučaj matrice COV), $COVx = \lambda x$, za neki skalar (konstantu) λ .

Simetričnost matrice kovarijanci, prema poučku o *simetričnoj Schurovoj dekompoziciji*⁶⁷ jamči da će njezine svojstvene vrijednosti biti realni brojevi i da će svojstveni vektori biti međusobno *ortogonalni*, tj. *linearno nezavisni*.

⁶⁷ O kojemu čitatelj u kontekstu primjene metode PCA ne mora ni mrvicu brinuti.



SLIKA 4-9: Skup podataka iz vizure kovarijanci (gornji red) i varijanci (donji red).
 (preuzeto s poveznice <https://www.visiondummy.com/2014/04/geometric-interpretation-covariance-matrix/>).

U trećem koraku svojstveni vektor (matrice kovarijanci COV) računa se kao rješenje matrične jednadžbe $(COV - \lambda I)x=0$, gdje je I jedinična matrica istog reda kao i matrica COV. Iz osnova linearne algebre zna se da homogena (desna strana jednaka je nul-matrici) matrična jednadžba $(COV-\lambda I)x=0$ ima netrivialno bazično rješenje⁶⁸ ako je njena determinanta⁶⁹ jednaka 0,

$$|COV-\lambda I|=0.$$

Rješenjem te jednadžbe dobivaju se svojstvene vrijednosti polazne matrice. Evo primjera:

$$\text{Izračunati svojstveni vektor matrice } A = \begin{bmatrix} -5 & 2 \\ -7 & 4 \end{bmatrix}.$$

⁶⁸ Ostala rješenja su linearne kombinacije bazičnih rješenja.

⁶⁹ Čitatelju zasigurno poznata bar za slučaj kvadratnih matrica reda 2.

$$\text{Mora biti } \left| \begin{bmatrix} \lambda + 5 & -2 \\ 7 & \lambda - 4 \end{bmatrix} \right| = 0, \text{ iz čega}^{70} \text{ slijedi}$$

$(\lambda+5)(\lambda-4)+14=0$, tj. $\lambda^2+\lambda-6=0$, što daje rješenja $\lambda_1=2$ i $\lambda_2=-3$. Bazične svojstvene vektore za svaku vrijednost svojstvene matrice dobit ćemo tako da u matričnu jednadžbu $(A-\lambda I)x=0$ redom uvrstimo svojstvene vrijednosti λ_1 , odnosno, λ_2 i riješimo pripadajući sustav dviju linearnih jednadžbi s dvije nepoznanice, x_1 i x_2 , za vektor $x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$. To činimo samo za $\lambda_1=2$. Dakle, rješavamo matričnu jednadžbu:

$$\left(\begin{bmatrix} -5 & 2 \\ -7 & 4 \end{bmatrix} - 2 \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \right) \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$


Objе jednadžbe su istovjetne, $-7x_1+2x_2=0$, pa su rješenja parametarska. Stavimo li $x_1=t$, onda je $2x_2=7t$, iz čega je $x_2=(7/2)t$. Ovdje t možemo birati po volji jer su svi bazični vektori ravnopravni, pa će mo ga izabrati tako da dobijemo „lijepe“ vrijednosti. Izaberemo li $t=2$, onda je $x_1=2$ i $x_2=7$. Dakle (jedan) bazični svojstveni vektor polazne matrice je $\begin{bmatrix} 2 \\ 7 \end{bmatrix}$. Drugi se računa na isti način.

Vrativši se matrici kovarijanci slučajnih varijabli u razmatranju, zaključujemo da će, bude li ona dijagonalna, pripadajuće kovarijance između parova varijabli biti jednake 0, dok će dijagonalni elementi, ujedno svojstvene vrijednosti, biti jednaki varijancama tih varijabli. U geometrijskom prikazu varijance prikazuju gomilanje podataka duž koordinatnih osi, dok kovarijance prikazuju stvarne vizure njihova gomilanja. Ilustrira

⁷⁰ Prema pravilu za računanje determinante matrice drugog reda.

to sljedeća skupna slika, na kojoj je svaka matrica pretpostavljeno matrica kovarijanci.


Da bi treći korak metode PCA uopće bio valjan, treba se uvjeriti da matrica kovarijanci predstavlja linearnu transformaciju podataka (višedimenzionalnih vektora). Zorno je najjednostavniji slučaj dvodimenzionalne matrice kovarijanci. Može se pokazati da je svaka ona rezultat (uzastopnih) dilatacija i rotacija, tzv. *bijelih podataka*, koji se, slikovito rečeno, mogu opisati kao „najslučajniji“ slučajni podaci, generirani tzv. *bijelim šumom* (Slika 4-10).



SLIKA 4-10: Bijeli šum.

Karakterizira ih jedinična matrica kovarijanci $\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$, s dilatacijskim faktorom α .


Dovoljno se uvjeriti da su te dvije transformacije linearne i da imaju *inverz*, tj. da postoji transformacija koja vektore vraća u polazno stanje. Intuitivno je to jasno. Rotiramo li vektor oko ishodišne točke za kut α , u početnu ćemo ga poziciju vratiti rotirajući ga za isti kut u suprotnom smjeru, tj. kut $-\alpha$. Dilatiramo li vektor faktorom α , na početnu duljinu vratit ćemo ga dilatacijom faktorom $(1/\alpha)$.



SLIKA 4-11: Bijeli podaci.

(preuzeto s poveznice <https://www.visiondummy.com/2014/04/geometric-interpretation-covariance-matrix/>).

Da čitatelja podsjetimo na srednjoškolsku trigonometriju, pokažimo da je rotacija dvodimenzionalnog vektora linearna transformacija, tj. da je rotacija za kut α , pa zatim za kut β , istovjetna rotaciji za kut $(\alpha+\beta)$. Za to moramo koristiti prikaz vektora u polarnim koordinatama. U njima je on određen duljinom i kutom koji zatvara s pozitivnim smjerom osi x , kao na Slici 4-12.



SLIKA 4-12: Vektor (x,y) u polarnom koordinatnom sustavu.

Slika 4-13 prikazuje vektor (x',y') , nastao rotiranjem vektora (x,y) u istom smjeru, za kut β . Koristeći poznate⁷¹ formule za cosinus i sinus zbroja dvaju kutova, dobivamo:

$$x' = r \cos(\alpha + \beta) = r \cos \alpha \cos \beta - r \sin \alpha \sin \beta$$


$$y' = r \sin(\alpha + \beta) = r \sin \alpha \cos \beta + r \cos \alpha \sin \beta$$

Uvrštavanjem $x = r \cos \alpha$ i $y = r \sin \alpha$ u gornje jednakosti, izlazi

$$x' = x \cos \beta - y \sin \beta, \text{ i}$$

$$y' = y \cos \beta + x \sin \beta,$$

čime se uvjeravamo da je rotacija vektora uistinu linearna transformacija.



SLIKA 4-13: Vektor (x',y') u polarnom koordinatnom sustavu.

Za čitatelja zabrinutog za translacije dobra vijest je poučak koji kaže da svako gibanje (zadržimo se na ravnini) koje je rezultat kombinacije translacija i rotacija može biti zamijenjen samo jednom rotacijom.

Sad kad smo se uvjerali da su rotacija i dilatacija vektora linearne transformacije, a to je i svaka njihova uzastopna primjena u bilo kojem slijedu, jasno je da ćemo svaki skup podataka sa Slike

⁷¹ Tu se pozivamo na srednjoškolsku trigonometriju.

4-9 dobiti njihovom uzastopnom primjenom na „bijeke podatke“. Naravno, vrijedi i obratno, što zapravo i znači da matrica kovarijanci slučajnih varijabli predstavlja linearnu transformaciju podataka i da su njezine svojstvene vrijednosti upravo varijance.

Sada se možemo vratiti metodi PCA.

Računanjem svojstvenih vrijednosti i svojstvenih vektora „u pozadini“, polazeći od inicijalnih, koreliranih varijabli, oblikovane su nove kao njihove linearne kombinacije⁷². Varijance tih novih varijabli iskazane su svojstvenim vrijednostima matrice kovarijanci. Varijance (svojstvene vrijednosti) su pozitivni realni brojevi. Veća varijanca znači veću raspršenost podataka i time njihov veći *informacijski sadržaj* (naboj). Podaci koji su bliže jedni drugima „skutreni“ su i imat će manju vrijednost varijance.

Svojstvene vrijednosti matrice kovarijanci sada se svrstavaju u padajućem poretku i odlučuje se koliko njih je dovoljno za očuvanje (u zadovoljavajućoj mjeri) informacijskog sadržaja inicijalnih podataka, a koje će se odbaciti.

U četvrtom koraku metode PCA od svojstvenih vektora matrice kovarijanci gradi se tzv. *matrica svojstava* na način da njezini stupci postaju svojstveni vektori, sukladno padajućem slijedu izabраниh varijanci.

U petom, ujedno posljednjem koraku metode PCA, izvorni podaci preoblikuju se tako da se transponirana⁷³ matrica svojstava množi s transponiranom matricom standardiziranih izvornih po-

⁷² Čitatelja ipak treba upozoriti da se time žrtvuje određeni stupanj „prozračnosti“ odnosno intuitivnog poimanja modela slučajnih podataka opisanog izvornim slučajnim varijablama.

⁷³ Iz izvorne matrice transponirana matrica nastaje zamjenom njezinih redaka i stupaca. Prvi redak postaje prvi stupac,...

dataka. Time će se izvorni skup podataka smanjiti i preorijentirati duž osi izabranih glavnih komponenata.

Razumijevanju metode PCA puno bi pomoglo eksperimentiranje s javno dostupnim skupovima podataka ili vlastitima, u okružjima kao što su Python, R, itd. Od znanstvenika u humanističkom području ne očekuje se ovladavanje svim njezinim aspektima, ali je određena razina razumijevanja neizbježna.

Burrowsova metoda Delta

Za razliku od metode PCA, koja je metoda „opće namjene“, Burrowsova metoda Delta namijenjena je specifično potrebama stilometrije u domeni teksta. Izvorno je opisana u članku (Burrows, 2002). Cilj joj je otkriti izgledno autorstvo izabranog teksta služeći se bazom podataka autora i pridruženih im tekstova. *Delta* (u daljnjem tekstu Δ) u imenu metode numerički je parametar koji mjeri razliku između izabranog teksta nepoznatog autora i tekstova poznatih autora. Najizglednijim autorom nepoznatog teksta prihvaća se poznati autor s najmanjim iznosom parametra Δ . Među ostalim, sam Burrows svoju metodu primijenio je na proučavanje stilskih obilježja engleskih prijevoda djela starorimskog (rođenog oko 55 g. N.E.) satiričara Juvenala.

Ideja metode Δ jest statističko vrednovanje određenog broja najčešćih riječi koje se javljaju u izabranim tekstovima. Prema (Savoy, 2020) 150 njih obično je najučinkovitiji izbor.

Sušтина metode Δ sastoji se od sljedećih šest koraka:

1. Za svaki tekst u bazi podataka računa se relativna frekvencija $f_i(w)$ za svaku izabranu riječ w u tekstu.

2. Računaju se očekivanja $\mu_{a_i}(w)$ i $\mu(w)$ i standardne devijacije $\sigma_{a_i}(w)$ i $\sigma(w)$ izabranih riječi (a_i), za svakog autora pojedinačno i cijelu bazu autora.
3. Računaju se z -frekvencije za svaku izabranu riječ w za svakog autora u bazi podataka,
4. Za svaki uzorak teksta s , računaju se frekvencije $f_s(w)$ i njihove z -frekvencije s obzirom na prosjek njihovih frekvencija u odnosu na cijelu bazu podataka.

$$z_{a_i}(w) = \frac{\mu_{a_i}(w) - \mu(w)}{\sigma(w)}$$

5. Za svakog autora parametar Δ računa se kao

$$\Delta s(a_i) = \frac{1}{|M|} \sum_{w \in M} |z_s(w) - z_{a_i}(w)|$$

6. Na kraju, vrijednosti parametra Δ uspoređuju se po svim autorima.

Eksperimentiranje metodom i ovdje pomaže, kako samom njezinu razumijevanju, tako i lagodnijem korištenju za potrebe istraživanja. Dobra vijest za čitatelja jest da postoje gotove biblioteke funkcija za te potrebe. Jedna, napisana u jeziku Python, može se povući s poveznice <https://github.com/cophi-wue/pydelta>. Pristup je slobodan. Drugi izvor, s izravnom implementacijom metode u jeziku Python jest <https://programminghistorian.org/en/lessons/introduction-to-stylometry-with-python#third-stylometric-test-john-burrows-delta-method-advanced>. Čitatelj bi trebao lakše proći kroz priloženi primjer.

Teorijsku interpretaciju Burrowsove metode čitatelj će naći

u, primjerice, (Argamon, 2007).

Labbèovska međutekstovna udaljenost

Autori ove mjere sličnosti tekstova su Cyril i Dominic Labbé, stoga *Labbèovska*, a ne *Labbéova*.

Ova mjera sličnosti tekstova opisana je u (D. Labbé, 2007) i (C. Labbe, 2005). Izlažemo je ukratko prema (Savoy, 2020). Ona predstavlja realan broj s rasponom vrijednosti 0,0 do 1,0 te se kao takva može smatrati mjerom vjerojatnosti autorstva nepoznatog teksta.

Segmenti teksta na kojima metoda utvrđivanja mjere sličnosti tekstova počiva nisu samo riječi, već tzv. *termi*, koji obuhvaćaju sve segmente leksike teksta po izboru istraživača. Uvjet za njezinu valjanu primjenu su visokokvalitetni tekstovi duljine 5000 znakova ili više i bez tipkarskih pogrešaka.

Također, svaki autor u razmatranju reprezentiran je svojim cjelokupnim djelom u dosegu dostupnom istraživaču, uključujući sve žanrove teksta (roman, novela, drama, poema, prepiska putem društvenih mreža,...). Za svaki tekst generira se njegov surogat sukladno apsolutnim frekvencijama izabranih terma i dodjeljuje mu se stvarni autor.

Nepoznati tekst, u izvornoj oznaci Q , prolazi istu proceduru, ali se surogatni tekst ovaj put generira sukladno apsolutnim frekvencijama izabranih terma. Zatim se računa tekstovna udaljenost između nepoznatog teksta i svih preostalih tekstova u razmatranju. Formula⁷⁴ kaže:

⁷⁴ Iako se riječima valjano iskazuje, formula u (Savoy, 2020) napisana je bez operatora apsolutne vrijednosti razlika frekvencija izabranih terma.

$$D_{Labbé}(A, Q) = \frac{\sum_{i=1}^m |\hat{tf}_{i,A} - tf_{i,Q}|}{2n_Q},$$

Ovdje je m ukupan broj terma u razmatranju, a n_A i n_Q broj terma teksta A , odnosno Q . Izraz

$$\hat{tf}_{i,A} = tf_{i,A} \frac{n_Q}{n_A}$$

ujednačava apsolutne frekvencije izabranih terma s obzirom na veličinu teksta A , odnosno Q , pod pretpostavkom da je tekst A veći od teksta Q . Faktor $2n_Q$ u nazivniku zapravo je $n_A + n_Q$, nakon ujednačavanja broja terma u oba teksta slijedom gornjeg izraza.

Kao i većina statističkih metoda namijenjenih potrebama stilometrije, i *Labbéova* metoda mjerenja sličnosti između tekstova nastala je pretakanjem konceptualnih ideja u statističko ruho, uz daljnja eksperimentiranja koje su ih potvrđivale ili ne. Nakon toga slijedila su nastojanja za valjanim teorijskim zasnivanjem, uključujući i unapređenje izvornih metoda. Metoda PCA, kao i Burrowsova metoda Δ , dobile su taj „pozitivan“ teorijski okvir, dok je *Labbéova* negdje na pola puta između korištenja i unapređivanja i znanstvenih kritika. Za prvo vidjeti primjerice (Merriam, 2003) i (Cortelazzo i sur., 2013), a za potonje (Viprey i Ledoux, 2006). S obzirom na to da je korištena u potjeri za stvarnim identitetom Elene Ferrante, ovdje smo je ukratko izožili.

Burrowsov test Zeta

Kao i Labbeéovska mjera međutekstne udaljenosti, i Burrowsov test *Zeta* predstavlja specifičan stilometrijski test sličnosti tekstova. Izvorni test kritiziran je i unapređivan. Najbolje se to ogleda u radovima P. Rizvia (Rizvi, 2018, 2018b, 2022) koje uzimamo za prikaz testa.

Ideja testa *Zeta* prema Burrowsu jest sučeliti tekst nepoznatog autora s tekstovima dvaju poznatih autora, svrstanih u dvije odvojene skupine (bazni tekstovi i kontratekstovi)⁷⁵ u cilju utvrđivanja izglednosti da autor nepoznatog teksta bude jedan od dvaju autora sučeljenih skupina tekstova. Tekstovi u obje skupine podijeljeni su u segmente jednakih veličina, osim zadnjega koji može biti do dvostruko veći od ostalih. Isto vrijedi i za tekst nepoznatog autora. Duljina segmenata kod različitih istraživača varira u rasponu od nekoliko stotina do nekoliko tisuća riječi. Objekti na kojima test *Zeta* djeluje općenito nisu (ali mogu biti) smislene leksičke jedinice, već bilo koji ulomci teksta (*tipovi*, engl. *types*) koji se mogu uočiti i brojčano mjeriti (riječi, sklopovi riječi, N-grami,...).

U sljedećem koraku za svaki izabrani *tip* računa se zbroj segmenata (*indeks*) u kojima on nastupa u skupini tekstova, odnosno ne nastupa u skupini kontratekstova. Formula je sljedeća:

$$Z_t = \frac{s_1(t, T)}{s(T)} + \frac{s_0(t, K)}{s(K)},$$

gdje $s_1(t, T)$ predstavlja broj segmenata u skupini tekstova u kojima

⁷⁵ Iako se to eksplicitno ne kazuje, na skupinama tekstova uspostavljen je implicitni uređaj, na način da skupina baznih tekstova ima „veći značaj“ za test.

tip t nastupa, $s_0(t, K)$ broj segmenata u skupini kontratekstova u kojima t ne nastupa, dok $s(T)$, odnosno $s(K)$ predstavlja ukupan broj segmenata u svakoj od njih.

Najveća vrijednost indeksa Z_t je 2, što znači da tip t nastupa u svim segmentima bazne skupine tekstova i ni u jednom segmentu skupine kontratekstova, što opet znači da tip t u najvećoj mogućoj mjeri razdvaja skupinu baznih tekstova od skupine kontratekstova.

Najmanja vrijednost indeksa Z_t je 0, što znači da tip t ne nastupa ni u jednom segmentu bazne skupine tekstova i nastupa u svim segmentima skupine kontratekstova. Ovdje se jasno vidi spomenuti implicitni uređaj na skupinama tekstova.

Za krajnji tekst bira se određeni broj⁷⁶ tipova s najvećom vrijednosti indeksa Z_t .


Na kraju, test *Zeta* računa dvije *Zeta*-vrijednosti (engl. *Zeta-scores*) na sljedeći način:

Prva Z-vrijednost računa se tako da se za svaki tip t među njih 500, s najvišim vrijednostima indeksa Z_p , računa broj nastupa za svaki segment skupine tekstova, skupine kontratekstova, teksta nepoznatog autora i kontrolnog teksta, nastalog nasumičnim izborom segmenata tekstova poznatih autora te uprosječuje ukupnim brojem tipova u tome segmentu.

Druga Z-vrijednost računa se na isti način, ali sa zamijenjenim ulogama bazne skupine tekstova i skupine kontratekstova. Naravno, mijenja se i skup 500 najvećih vrijednosti indeksa Z_p , koji se sada računa za skupinu kontratekstova.

⁷⁶ Često 500, pa ćemo ga u tome kontekstu koristiti u daljnjem opisu testa.

Ostaje pitanje interpretacije skupova prve i druge Z-vrijednosti u kontekstu nepoznatog autorstva poznatog teksta. Ona počiva na dijagramu njihove raspšrenosti. Os x toga dijagrama predstavljaju proporcije segmenata tipova t zastupljenijih u prvom skupu Z-vrijednosti, a os y onih u skupu drugih Z-vrijednosti. Jedan takav dijagram prikazan je na sljedećoj slici. Ne komentiramo ga jer ćemo ga u sklopu „potjere“ za Elenom Ferrante uskoro ponovno sresti.



SLIKA 4-I4: Dijagram raspšrenosti segmenata ... (Savoy, 2020).

Sukladno uvriježenoj interpretaciji, gomilišta lijevo gore i desno dolje, razdvajaju na ranije opisani način segmente skupine baznih tekstova, kontratekstova, testnih tekstova, odnosno tekst nepoznatog autora te tako ukazuju na autorstvo potonjeg.

Međutim, P. Rizvi u (Rizvi, 2018) kritizira (s pravom) takvu interpretaciju, konstatirajući da je tome tako upravo zbog načina konstrukcije dijagrama raspšrenosti. U radu (Rizvi, 2018) P. Rizvi,

kroz detaljnu analizu formule za računanje indeksa Z_t (str. 154) na tri stranice sitnopisa, daje novu formulu za njegovo računanje, usput pojednostavnjujući i sam test *Zeta*. Rizvieva formula glasi ovako:

$$Z_t = \frac{s_{\geq 1}(t, T)}{s(T)} - \frac{s_{\geq 1}(t, K)}{s(K)},$$

gdje je $s_{\geq 1}(t, T)$ broj segmenata u skupu baznih tekstova u kojima tip t nastupa jedan ili više puta. Analogno značenje ima i oznaka $s_{\geq 1}(t, K)$, dok su preostale dvije oznake istovjetne prethodnima.

Na kraju ovoga kratkog prikaza Burrowsova testa *Zeta* treba konstatirati da on svakako ima solidan potencijal u primjeni na stilometrijske probleme u domeni teksta, ali da ga treba primjenjivati vrlo pažljivo i promišljeno. Kao jedan od pomoćnih zahvata koji prethode primjeni testa *Zeta* predlaže se primjena metode PCA.

A la reserche du Elena Ferrante⁷⁷

Jedna od, može se slobodno reći, slavni stilometrijskih potjera novijeg vremena jest ona za stvarnim autorstvom tetralogije *L'amica Geniale*⁷⁸ (u nas prevedena kao *Moja genijalna prijateljica*).

Iz nekih razloga autor⁷⁹ je odlučio pisati pod pseudonimom, što je svakako, ako mu je to bio cilj, pridonijelo iznimno velikoj popularnosti djela, uključujući i njegovu djelomičnu ekranizaciju.

Tajanstvenost autora potaknula je medijska nagađanja koja su iznjedrila određeni prostorni i vremenski okvir potencijalnih

⁷⁷ Da parafraziramo naslov čuvenog romana M. Prousta, *A la reserche du temps perdu* (*U potrazi za izgubljenim vremenom*).

⁷⁸ Prva knjiga iz serije. Često se sreće i pod imenom *Napuljska tetralogija*.

⁷⁹ *Autor* je ovdje rodno neutralna imenica u značenju *autor/autoric*.

autora djela, oba spola.

S obzirom na razinu poznavanja društvenih odnosa u Italiji toga doba, posebice u pokrajini *Kampaniji* (*Campania*), kojoj pripada i Napulj, u kojemu se odvija dobar dio radnje djela, pretpostavilo se da je autor morao biti u zreloj spisateljskoj dobi pedesetih godina prošlog stoljeća te da potječe iz samog Napulja ili okolne regije. S obzirom da djelom promiču pretežito junakinje ženskog spola, smatralo se da bi i autor bio ženskog spola, itd.

Nakon niza godina anonimnosti autora tetralogije, skupina znanstvenika sa sveučilišta u Padovi, pod vodstvom profesorice A. Tuzzi i profesora M. Cortelazza, odlučila je 2017. g. pokrenuti istraživanje stilskih obilježja pisanja suvremenih talijanskih spisatelja oba spola, kako bi skinula veo anonimnosti sa stvarnog autora.

Među kriterijima za izbor tekstova za analizu, a time i autora, bili su i sljedeći:

- Zastupljeni su autori oba spola, rođeni pretežito u određenom vremenskom razdoblju u Napulju ili okolnoj regiji, ali i oni s podrijetlom iz drugih talijanskih regija.
- Broj autora ženskog spola morao je biti iznad određenog praga.
- Iz opusa Elene Ferrante isključena su djela pisana za djecu, kao i zbirke pisama, intervjua⁸⁰ i eseja.
- U izbor tekstova za stilometrijsku analizu ušla su samo od strane kritike najhvaljenija i najnagrađivanija djela.
- Zastupljeni su svi autori spomenuti u kontekstu medijskih nagađanja o Eleni Ferrante.

⁸⁰ Vjerojatno prepiskom ili uz jamstvo čuvanja identiteta.

TABLICA 4-I. Izbor autora i djela u potrazi za Elenom Ferrante.
Izvor: (Savoy, 2020)

Prezime	Spol	Regija	# Djela	Prezime	Spol	Regija	# Djela
Affinati	M	Lazio	2	Montesano	M	Camp.	2
Ammaniti	M	Lazio	4	Morazzoni	F	Lomb.	2
Bajani	M	Lazio	3	Murgia	F	Sard.	5
Balzano	M	Lomb.	2	Nesi	M	Tosc.	3
Baricco	M	Piem.	4	Nori	M	Emil.	3
Benni	M	Emil.	3	Parrella	F	Camp.	2
Brizzi	M	Emil.	3	Piccolo	M	Camp.	7
Carofiglio	M	Puglia	9	Pincio	M	Lazio	3
Covacich	M	Friuli	2	Prisco	M	Camp.	2
De Luca	M	Camp.	4	Raimo	M	Lazio	2
De Silva	M	Camp.	5	Ramondino	F	Camp.	2
Faletti	M	Piem.	5	Rea	M	Camp.	3
Ferrante			7	Scarpa	M	Veneto	4
Fois	M	Sard.	3	Sereni	F	Lazio	6
Giordano	M	Piem.	3	Starnone	M	Camp.	10
Lagioia	M	Puglia	3	Tamaro	F	Friuli	5
Maraini	F	Tosc.	5	Valerio	F	Lazio	3
Mazzantini	F	Lazio	4	Vasta	M	Sici.	2
Mazzucco	F	Lazio	5	Veronesi	M	Tosc.	4
Milone	F	Camp.	2	Vinci	F	Lomb.	2


Dalje, tekstovi su filtrirani prema određenim kriterijima koje će čitatelj naći u (Savoy, 2020) ili u drugim publikacijama na ovu temu te su svi tekstovi pojedinačnih autora spojeni u jedan, što je dalo ukupno 40 tekstova za daljnju obradu. Nakon toga postalo je moguće profiliranje autora prema određenim kriterijima i testovima koji se žele primijeniti. Jedan od njih je analiza zbirnih tekstova izabranih autora s obzirom na određeni broj⁸¹ najučestalijih riječi talijanskog jezika⁸².

⁸¹ U ovom slučaju 50.

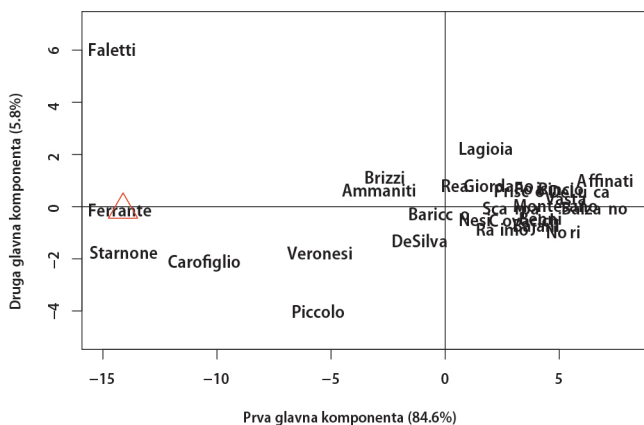
⁸² Popis se može naći u (Savoy, 2020).

Slijedilo je nekoliko testova analize glavnih komponenata, koja, da čitatelja podsjetimo, višedimenzionalni skup podataka reducira na skup podataka manje dimenzije (najčešće 2) uz maksimalno očuvanje varijabilnosti u podacima.

Jedan od testova sučelio je profil Elene Ferrante profilima svih talijanskih spisatelja koji su uzeti u obzir, drugi samo sa spisateljicama, a treći samo sa spisateljima. Prema⁸³ (Savoy, 2020), prikazujemo ih na sljedećoj zbirnoj slici.



⁸³ Podebljano pismo i prijevod engleskog teksta.



SLIKA 4-I5: Neki profili analize djela talijanskih spisatelja u potrazi za Elenom Ferrante.

Čitatelja podsjećamo da su atributi na koordinatnim osima izgubili svoj izvorni smisao i da su sada proizvod matrice kovarijanci.

Prema rezultatima analize glavnih komponentata izlazi da od spisateljica iza pseudonima Elena Ferrante kao „sumnjivo lice“ najizglednije stoji M. G. Mazzuco, a od spisatelja D. Starnone.

Još jedan test glavnih komponentata, ograničen na spisatelje podrijetlom iz regija Kampanija također naglašava stilsku bliskost tekstova Elene Ferrante i D. Starnonea.

Sljedeći primijenjeni test bio je test Δ koji je mjerio razlike u stilovima pisanja izabranih spisatelja.

U prvom koraku metode Δ bira se skup često korištenih riječi na kojima će se tražiti stilske različitosti među izabranim spisateljima. Broj takvih riječi u testnom skupu najčešće se kreće u rasponu od 50 do 1000 njih.

U drugom koraku metode Δ stvara se stilski profil svakog spisatelja, izostavljajući Elenu Ferrante. Za to se svi tekstovi svakog poje-

dinačnog spisatelja spajaju u jedan i na njima se računaju standardizirane frekvencije (*z-frekvencije*) riječi iz izabranog testnog skupa.

U trećem koraku metode Δ na isti se način vrednuje svaki sporni tekst (u ovom slučaju tekst Elene Ferrante) i računa pripadajuća *Z*-vrijednost. Zatim se za svakog poznatog autora posebice, u sprezi s nepoznatim, prema formuli na str 152. računa vrijednost parametra Δ . Stilski bliži nepoznatom autoru su poznati autori s manjim vrijednostima Δ .

Dobiveni rezultati, prikazani u sljedećoj tablici, pokazuju da i ovaj test najveće izglede kao Eleni Ferrante daje D. Starnoneu.

TABLICA 4-2. Rezultati testa Δ u potrazi za Elenom Ferrante.

IZVOR: (Savoy, 2020)

Rang	<i>L'amore molesto</i>		<i>L'amica geniale</i>		<i>Storia bambina perduta</i>	
1	0.495	Starnone	0.522	Starnone	0.572	Starnone
2	0.657	Brizzi	0.582	Balzano	0.671	Balzano
3	0.666	Milone	0.650	Milone	0.691	Veronesi
4	0.695	Sereni	0.705	Veronesi	0.703	Carofiglio
5	0.724	Tamaro	0.711	Prisco	0.708	Milone

Labbéovska međutekstovna udaljenost također mjeri stilske razlike u tekstovima različitih autora. Za razliku od metode Δ , izvorni tekstovi ovdje se zamjenjuju surogatnima, a testni skup riječi obuhvaća sve tipove leksičkih jedinica. Tekstovi poznatog autora opetovano se sučeljuju s tekstovima nepoznatog autora i rezultati se rangiraju u rastućem poretku. Za više detalj vidjeti, primjerice, (Savoy, 2020). U sučeljavanju s tekstovima Elene Ferrante pobjednik je ponovo D. Starnone.

Test *Zeta* uspoređuje tekstove poznatog i nepoznatog autora, brojeći kod jednoga broj riječi iz ukupnog testnog skupa koje u

njima nastupaju najčešće, a kod drugoga najmanje često. Temeljem tih frekvencija računaju se Z-vrijednosti testa. Ovdje veća vrijednost Z-vrijednosti znači veću sličnost stilova dvaju autora. I ovaj put pobjednik je D. Starnone.

Zaključak opisanih testova je da iza pseudonima Elena Ferrante s vrlo visokom vjerojatnošću stoji spisatelj D. Starnone. Pa neka se pokaže!



SLIKA 4-16: Domenico Starnone.

Izvor: <https://forlagetgrif.dk/media/1183/domenico-starnone.jpg>

Problem lažnih vijesti

Tzv. *lažne vijesti*, u svim vrstama medija, posebice mrežnih (*online*), danas predstavljaju značajan problem ne samo za pojedince, već i šire društvene zajednice, uključujući i države te u krajnjoj instanci cijeli svijet. Mnoge su manje ili više bezazlene (*prvotravanjske šale*, ili *novinske*, odnosno *novinarske patke*⁸⁴), iako su i one znale podići veliku prašinu u javnosti⁸⁵, ali takvih

⁸⁴ O podrijetlu sintagme *novinska patka* više na poveznici https://hr.wikipedia.org/wiki/Novinska_patka.

⁸⁵ Sjetimo se samo radijske izvedbe djela *Rat svjetova* (*The War of the Worlds*) H. G. Wellsa, od 31. listopada 1938. g., u izvedbi poznatog glumca Orsona Wellesa, koja je neke slušatelje (teško za povjerovati, ali uistinu jest) uvjerila da su Marsovci učinili invaziju na Zemlju.

je sve manje. Plasiranje lažnih vijesti u suvremeno doba, kroz sve vrste javnih medija, u današnje vrijeme ponajviše kroz internetske, ima zadaću obmanuti javnost u širokom društvenom okružju, u rasponu od lokalne zajednice pa do svjetskih razmjera, s ciljem postizanja ekonomske (manipulacije na burzama,...) ili političke (uplitanje u izbore,...) koristi (neposredne, ili češće, posredne). I posljednja globalna zdravstvena kriza (COVID-19), kojoj još uvijek svjedočimo, mogla je proći puno bezbolnije da nije bilo mnogostrukog masovnog širenja lažnih vijesti o cjepivu, posljedicama cijepljenja, itd.

Nikako nije zanemariv ni, uvjetno rečeno, suprotan trend, koji vijesti koje su neugodne za pojedince, šire društvene grupe ili organizacije, gospodarske ili političke subjekte,..., nastoji sakriti („staviti pod tepih“), relativizirati ili njihov izvor prikazati nepouzdanim, itd.

Glede lažnih vijesti, i ovdje nas Guy de Maupassant u već spomenutom djelu *BEL-AMI* spominje tome da lažne vijesti nisu *od danas*:

Urednik Forestier daje Duroyu zadaću da pod nadzorom iskusnog novinara Saint-Potina⁸⁶ za novine »Francuski život« napravi intervju s dvojicom stranaca⁸⁷ (general Li-Theng-Fao i radža Taposahib Ramadera Pali) koji netom borave u Parizu i da se posebice raspitaju o tome što ta dvojica odličnika misle o engleskom političkom, vojnom i ekonomskom rovaranju, posebice u Aziji.

⁸⁶ *Saint-Potin* bi se prevelo kao *Sveto Ogovaralo*.

⁸⁷ Vrlo izvjesno izmišljenih, *op. a.*

Dijalog Saint-Potin—Duroy

Kad odu na zadatak, svrate na piće.

Pošto je platio ono što su popili, Duroy proslijedi:

— Čini mi se da je kasno i da moramo posjetiti onu dvojicu odličnika.

Saint-Potin se zasmije:

— Ala ste vi još naivni! Znači, vi zaista vjerujete da ću ići pitati toga Kineza i tog Indijca što misle o Engleskoj? Kao da ne znam bolje nego oni što moraju misliti za čitaoce »Francuskoga života«. Već sam intervjuirao pet stotina takvih Kineza, Perzijanaca, Hindusa, Čileanaca, Japanaca i drugih. Po mome pisanju svi oni odgovaraju isto. Ja samo uzmem članak o posljednjem gostu i od riječi do riječi ga prepisem. Ono što se, recimo, mijenja, to je njihovo lice, njihovo ime, njihovi naslovi, njihova dob, njihova pratnja! Oh, u ovome se čovjek ne smije zabuniti, jer bi me »Figaro« ili »Gal« odmah raskrinkali. Ali će me o tim pitanjima vratar u hotelu Bristol i vratar u hotelu Continental obavijestiti u pet minuta. ... Tako se, dragi moj, postupa ako je čovjek praktičan.,,

Za strukturne komunikacijske kanale za potrebe širenja lažnih vijesti, ili, kako se nekoć govorilo, *dezinformiranja*, brinula se i ozbiljna znanost. Njihovu proučavanju, u suštini, posvećena je primjerice cijela knjiga poljskog matematičara Mariana Mazura, (Mazur, 1970)⁸⁸.

Donedavna su lažne vijesti bile ograničene na pisanu i govornu komunikaciju, ali u današnje vrijeme sve češće ih se nalazi i u vizulnim medijima, posebice na Webu. Više o tome nešto kasnije.

U otkrivanju identiteta autora lažnih vijesti mogu pomoći

⁸⁸ Na tu temu, s Mazurovom knjigom (u ruskom prijevodu) kao temeljnim materijalom, autor je svojedobno u sklopu Specijalističkog poslijediplomskog studija FOI na temu sigurnosti (više se u tadašnjem obliku ne izvodi), studentima ponudio kolegij *Kvalitativni modeli dezinformiranja*. Navale na kolegij baš i nije bilo!


iste stilometrijske metode koje se koriste za otkrivanje identiteta nepoznatih autora teksta. Naime, isti „spisatelji“ najčešće su višestruko aktivni na društvenim mrežama (forumima, blogovima) i koriste isti stil⁸⁹ pisanja.

Stilometrijski problemi u vizualnom kontekstu

Do sada je o stilometriji bilo govora u kontekstu problema vezanih za tekst. Međutim, ona ima značajne primjene i u vizualnom kontekstu, posebice u domeni atribucije autorstva umjetničkih slika, s obzirom na tržišnu vrijednost djela klasika slikarstva, i ne samo njih. Spomenimo se samo događanja oko slike *Salvator Mundi* Leonarda da Vincija, koja je opetovano nestajala i pojavljivala se u javnom prostoru, učestalo mijenjala vlasnike i nakon zadnje restauracije, na dražbi u aukcijskoj kući Christie's u New Yorku, 2017. g., prodana za preko 450 milijuna USA\$.

O slici i njezinim atribucijama kroz povijest puno se može doznati na Web-stranicama aukcijske kuće Christie's, <https://www.christies.com/features/Salvator-Mundi-timeline-8644-3.aspx>, kao i na trodijelnom blogu <https://blog.oup.com/2022/11/salvator-mundi-the-journey-of-a-false-saviour/> (Salvator Mundi: the journey of a false saviour), <https://blog.oup.com/2022/12/leonardo-and-the-salvator-mundi-fame-and-infamy/> (Leonardo and the Salvator Mundi: fame and infamy) i <https://blog.oup.com/2022/11/salvator-mundi-poor-picture-poor-leonardo-da-vinci/> (Salvator Mundi: poor picture, poor Leonardo).

⁸⁹ Ovdje obogaćen „smješkićima“ i drugim grafičkim pismenima oblikovanih za iskazivanje stavova, sentimenata, itd.



SLIKA 4-17: Da Vinciev *Salvator Mundi*, prije i poslije restauracije.

Da Vincijevo autorstvo slike i danas je predmet znanstvenih istraživanja i rasprava, s dvojakim rezultatima. U nekim radovima, poput, primjerice, (Frank & Frank, 2021), korištenjem tehnologije konvolucijskih neuronskih mreža, slika se uistinu pripisuje Da Vinciju. To ni izdaleka nije jedini rad koji se bavi atribucijom slike *Salvator Mundi*, ali je, pored neupitne kvalitete, u kontekstu ranijeg govora o potrebi egzaktnog obrazovanja struka poput humanistike, značajan po tome što su se autori, bračni par Frank, muzejski kustos (gospođa Frank) i odvjetnik, specijaliziran za pitanja intelektualnog vlasništva (gospodin Frank), potrudili, u dobi bliže mirovini, svladati tehnologiju neuronskih mreža, posebice konvolucijskih, u mjeri koja im je omogućila valjano istraživanje.

Da Vinci nije jedini slikar sa spornim atribucijama autorstva. Uz bok mu stoje Rembrandt (vidjeti, primjerice (Fraile-Narváz i sur., 2022), Picasso i Matisss (Elgammal i sur., 2018) te mnogi drugi

(Cömert i sur., 2021)).


S druge strane, iste metode koje pomažu utvrđivanju upitnih autorstava umjetničkih slika, u stanju su proizvoditi i njihove vrhunske plagijate. Izvrstan primjer je sustav DALL•E⁹⁰ istraživačke tvrtke OpenAI, trenutačno u verziji *beta 2*, koji implementira vrlo složenu arhitekturu neuronskih mreža koja generira umjetničke slike temeljem njihova tekstualnog opisa, ili stilski varira slike/fotografije koje se u sustav unesu. Da bi se dobio pristup alatu i njime eksperimentiralo, potrebno je provesti vrlo jednostavan i brz proces registracije. S registracijom jednokratno se dobiva 50 besplatnih *kredita*, svaki sljedeći mjesec njih 15, a moguće ih je i dokupiti (brzo se troše!). Na sljedećih nekoliko slika vidljivi su rezultati upita sustavu za samostalno generiranje slika temeljem tekstualnog opisa, odnosno rezultati variranja slika dostavljenih sustavu od strane korisnika.

S obzirom na činjenicu da je sustav tek u fazi *beta 2*, rezultati su prilično impresivni, ne toliko u samom tekstualnom „sučelju“, već više u generativnim sposobnostima oponašanja stilova slikanja pojedinačnih slikara, odnosno variranja sustavu dostavljenih fotografija. Arhitektura neuronske mreže sustava i algoritmi njezina obučavanja opisani su u radu (Radford i sur., 2021).


Pored sučelja koje omogućuje korištenje sustava DALL•E bez bilo kakva poznavanja njegove unutarnje arhitekture i načina djelovanja, on omogućuje i napredno korištenje, nudeći za to biblioteku funkcija Images API, napisanu u jeziku JavaScript, s omotačem (engl. *wrapper*) za Python. Evo kako to izgleda na djelu (<https://beta.openai.com/docs/guides/images/usage>):

⁹⁰ <https://openai.com/dall-e-2/>.

1. Picasso wumen portrait



2. Watercolor sea landscape



3. Manet wumen portrait



4. Četiri varijacije na sustavu dostavljeni portret



SLIKA 4-18: DALL•E 2 na djelu.

```
Generate an image python Copy
1 response = openai.Image.create(
2   prompt="a white siamese cat",
3   n=1,
4   size="1024x1024"
5 )
6 image_url = response['data'][0]['url']
```




ili

```
Edit an image python Copy
1 response = openai.Image.create_edit(
2   image=open("sunlit_lounge.png", "rb"),
3   mask=open("mask.png", "rb"),
4   prompt="A sunlit indoor lounge area with a pool containing a flamingo",
5   n=1,
6   size="1024x1024"
7 )
8 image_url = response['data'][0]['url']
```

IMAGE

MASK

OUTPUT



SLIKA 4-19: DALL•E 2 API na djelu.

Još jedan pažnje vrijedan proizvod tvrtke OpenAI je ChatGPT, sustav za procesiranje prirodnog jezika (u najvećoj mjeri engleskog) u najširem smislu i koji pretendira postati sustavom

sveopće umjetne inteligencije (engl. *general artificial intelligence*).

Ipak, potpunosti informacije radi, napomenimo da ChatGPT svakako nije prvi sustav svoga roda. Kao jedan od važnijih spomenimo projekt Cyc (<https://en.wikipedia.org/wiki/Cyc>), koji od 1984. vodi Douglas Lenat, poznati znanstvenik u području simboličkog strojnog učenja i općenito umjetne inteligencije, koji se razvija i danas.

Algoritamske i logičke metode na usluzi stilometriji

Tekst kao objekt istraživanja već je dugo predmet primjene specifičnog segmenta struktura podataka i algoritama oslonjenih na teoriju formalnih gramatika i jezika⁹¹, logičke formalizme, kriptografiju, itd.,

U alate kao što su 7zip, WinZip, WinRar i brojni im srodni, ugrađeni su napredni algoritmi sažimanja teksta koje svakodnevno rutinski koristimo.

Za potrebe uređivanja teksta ili njegova prijeloma za tisak, u alatima kao što su MSWord, OpenOffice Writer, QuarkXPress, InDesign, Tex, Latex, i brojni drugi, ugrađeni su algoritmi za, primjerice, grafičko oblikovanje ulomaka teksta, poravnavanja teksta, itd.

Sva nebrojena lijepa pisma koja ponekad tijekom uređivanja teksta i zloupotrebjavamo na račun estetike, rezultat su algoritama za njihovo oblikovanje, temeljenima na tzv. *Bezierovim krivuljama*⁹²

⁹¹ S paralelom u teoriji (konačnih) automata.

⁹² Ovdje je red spomenuti se doprinosa profesora D. E. Knutha, vjerojatno najvećeg informatičara svih vremena (za sada) koji je za potrebe pisanja svoje čuvene serije knjiga *The Art of Computer Programming*, koju konstantno dodaje već gotovo tri i pol desetljeća, nezadovoljan ondašnjom tehnologijom

i ugrađenima u alate kao što su FontLab, FontForge i njima slični.

U sve kalkulatore, kako fizičke, tako i virtualne, ugrađeni su algoritmi za pretvaranje aritmetičkih (općenito algebarskih) izraza u tzv. *prefiksni* ili *postfiksni* zapis, u kojima aritmetička (algebarska) operacija dolazi prije ili poslije svojih operanada, koji slijedom konstrukcije ne sadrže zagrade te omogućuju ne samo rekonstrukciju u uobičajeni infiksni zapis (s operatorima između svojih operanada), već i valjane izračune njihovih vrijednosti. To nelinearnu strukturu binarnog stabla kojom su prikazani izrazi u infiksnom zapisu „pegla“, pretvarajući je u linearan niz znakova, s kojim je (kalkulatorima, računalima) puno lakše raditi. Kao struktura podataka dovoljan je najobičniji stog (tko se zadnji popne na stog, prvi s njega silazi).

Algoritme za rad s tekstem naći ćemo i u istraživanjima u domeni genetike, posebice molekularne, posebice vezane za strukturu i manipuliranje „molekulom života“, DNA⁹³.

Pored sintagme „algoritmi za rad s tekstem“ često se sreće i sintagma „algoritmi za rad sa stringovima“, tj. nizovima znakova. Suštinske razlike zapravo i nema, osim što se pod tekstem češće podrazumijevaju nizovi znakova koji imaju određenu strukturu, dok sa stringovima to općenito nije slučaj. Dobru usporedbu čitatelj će steći uvidom u dvije knjige u kojima se kao suautor javlja jedna te

slaganja matematičkih tekstova (nema informatike bez matematike), sam razvio tehnologiju računalnog sloga, programski alat i ujedno programski jezik Tex te alat i također programski jezik za oblikovanje računalnih pisama, Metafont. Sve to dokumentirao je u dvije obimne knjige *T_EX: The Book* i *Metafont: The Book* te dao na besplatno korištenje svima koji su to željeli i trebali. Na tome smo mu vrlo zahvalni.

⁹³ Vidjeti, primjerice (Guesfeld, 2011).

ista osoba, (Crochemore i Rytter, 1994), odnosno (Crochemore i sur., 2007).

U (Crochemore i Rytter, 1994) raspisan je, u ravne 22 stavke, niz temeljnih algoritamskih problema vezanih za tekst, poput:

- Uparivanje stringova/tekstova⁹⁴ (engl. *string-matching*), tj pronalaznje zadanog steksta/tringa u širem tekstu/stringu.
- Udaljenost uređivanja (engl. *edit distance*). Za dva stringa traži se minimalni broj transformacija koje jedan tekst preoblikuju u drugi. Dopuštene operacije nad tekstem su umetanje znaka u tekst (izvorne abecede ili alfabeta), brisanje znaka iz teksta, odnosno zamjena jednog znaka drugim.
- Ciklička ekvivalencija stringova. Dva stringa, x i y , ciklički su ekvivalentna ako i samo ako postoje druga dva stringa, u i v , takva da je $x=uv$ i $y=vu$.

Formalne gramatike

Formalne gramatike su generatori formalnih jezika, skupova stringova generiranih skupom gramatičkih pravila. Njihovo formiranje u suvremenom teorijskom smislu veže se uz Noama Chomskog⁹⁵.

Formalne gramatike i formalni jezici danas čine jedno golemo područje teorije i primjena. Bez njih definitivno ne bi bilo suvremenih programskih jezika, kako univerzalnih, tako ni

⁹⁴ U daljnjem tekstu *uparivanje*.

⁹⁵ Avram Noam Chomsky (1928 -), lingvist, filozof, povjesničar, jedan od utemeljitelja područja kognitivnih znanosti, društveno angažirani intelektualac, pisac više desetaka knjiga, prevedenih na mnoštvo jezika, među njima i hrvatski.

domenski specifičnih. Danas, uz ne posebice zahtjevnu razinu poznavanja formalnih gramatika, uz pomoć alata kao što su *Xtext* i *Xtend* iz riznice golemog (i posve besplatnog) programskog razvojnog okružja *Eclipse*, svatko može generirati svoj „punokrvni“ programski jezik, sa svim suvremenim značajkama sintakse, uređivanja programa, utvrđivanja i uklanjanja pogrešaka u kôdu, praćenje izvođenja programa, prevođenja u strojni kôd ili u kôd u izabranom programskom jeziku, itd. Cijeli proces, vrlo detaljno i uz mnoštvo primjera, opisan je u (Bettini, 2016).

Vrlo zanimljivu klasu formalnih gramatika, prikladnu za ilustriranje opće ideje njihove uloge kao generativnih mehanizama (formalnih) jezika čine tzv. *slikovne gramatike* (engl. *picture grammars*). One svojim gramatičkim pravilima generiraju različite grafičke strukture poput biljaka, tipskih vrtova, ornamenata, dizajna uzoraka tkanina, građevina, kemijskih spojeva, itd. Jednu njihovu granu čine tzv. *L-sustavi*⁹⁶.

Za potrebe vizualiziranja gramatikama generiranih struktura najčešće se koristi tzv. *geometrija kornjače* (engl. *turtle geometry*), izvorno namijenjena obučavanju djece programiranju, (vidjeti, primjerice, (Abelson and Disessa, 1986) ili (Papert, 2020)), za što je svojevremeno razvijen i poseban programski jezik LOGO. Tijekom vremena geometrija kornjače pronašla je brojne druge primjene, poput modeliranja fraktala, Bezierovih krivulja, CAD-konstrukcija, skulptura, poput ove na slici 4-20 (Verhoeff, 2010), itd.

Jednu liniju primjene L-sustava čini modeliranje fraktal-

⁹⁶ Po mađarskom biologu Aristidu Lindenmayeru koji je prvi uobličio formalni model rasta biljnih stanica.

nih struktura s poopćenjem na modeliranje biljaka⁹⁷ i drugih bioloških struktura i organizama. Ona je sveobuhvatno izložena u (Prusinkiewicz i sur., 1996). Izuzetno bogata riznica materijala i informacija vezanih uz ovu specifičnu primjenu L-sustava nalazi se na poveznici <http://algorithmicbotany.org/>. Među ostalim, tu je i program L-studio, slobodno dostupan i namijenjen modeliranju biljaka, čak i u širem okruženju njihovih „staništa“ (virtualnih, daka-ko), kao što su vrtovi, morskih bića (školjke, spužve, koralji), itd.

L-sustavi

Gramatiku L-sustava u osnovnoj inačici čine sljedeća tri skupa znakova:

\mathcal{A} – abeceda, koju čine varijable i konstante (terminalni elementi).

ω – polazna konfiguracija kao niz znakova abecede.

\mathcal{P} – skup produkcija kao pravila koja mijenjaju *jednake za jednake*.

PRIMJER 4-I (Zmajeva krivulja)

$\mathcal{A} = \{F, G, +, -\}$. F i G su varijable, a + i – konstante

$\omega = F$

$\mathcal{P} = \{F \rightarrow F+G, G \rightarrow F-G\}$

Generirane riječi po generacijama iteriranja⁹⁸:

$r_1 = F$

$r_2 = F+G$

⁹⁷ I biljke su najčešće fraktalne strukture, dakle strukture slične sebi na različitim mjernim skalama.

⁹⁸ Napomenimo da se zamjene sukladno produkcijama/pravilima provode *istodobno* za sve nastupe svake varijable u riječi koja podliježe transformiranju. To je i razlog zašto L-sustavi imaju slabije izražajne mogućnosti u smislu generiranja jezika negoli standardne formalne gramatike općenito.

$$r_3 = F+G + F-G$$

$$r_4 = F+G + F-G + F+G - F-G$$

$$r_5 = F+G + F-G + F+G - F-G + F+G + F-G - F+G - F-G$$

$$r_6 = F+G + F-G + F+G - F-G + F+G + F-G - F+G - F-G + \\ F+G + F-G + F+G - F-G - F+G + F-G - F+G - F-G$$

Uočimo da gornji L-sustav nema terminalnih elemenata gramatike, što znači da on potencijalno generira riječi beskonačne duljine. U ovom slučaju to je razložno jer zmajeva krivulja za svoj rast ima cijelu ravninu. Jedno od njezinih svojstava jest da ako iz jedne fiksne točke ravnine pustimo rasti četiri zmajeve krivulje, onda će one proći kroz sve cjelobrojne točke unaprijed zadanog segmenta ravnine, neće se sjeći međusobno, a ni same sa sobom.



SLIKA 4-20: Skulptura generirana *L-sustavom*

Također uočimo da svaka nova iteracija produkcija L-sustava za generiranje zmajeve krivulje kao prefiks sadrži rezultat prethodne iteracije. Dakle, krivulja uistinu raste.

Geometrijska interpretacija je sljedeća:

F i G predstavljaju dužine jednake duljine koje se crtaju (crta ih „kornjača“) kao vodoravne ili uspravne.

+ i – predstavljaju promjenu smjera crtanja krivulje (kretanja

kornjače) za 90° u pozitivnom (suprotno smjeru gibanja kazaljke na satu), odnosno negativnom smjeru. Kut promjene smjera crtanja je vanjski promjenjivi parametar L-sustava.

Slika krivulje ovisi i o tome krenemo li inicijalno s vodoravnom ili uspravnom dužinom.

Netom L-sustavom generirani segment zmajeva krivulje implementiran je u „dječjoj“ varijanti geometrije kornjače, u programu PythonTurtle.

Na slici se čini da zmajeva krivulja samu sebe siječe, protivno ranije rečenom. Međutim, slijed iteracija same konstrukcije (u više od 25 slika, koji ovdje ne prikazujemo) pokazuje da krivulja samu sebe samo dotiče.

Mnoštvo glamuroznijih izvedbi, čak i uz nešto umjetničkog dodira koji zorno dočarava čime je zmajeva krivulja zaslužila svoje ime čitatelj će lako naći na mnoštvu internetskih poveznica.

PRIMJER 4-2: (Fraktalna biljka)

$\mathcal{A} = \{X, F, +, -, \square\}$. X i F su varijable, $+$, $-$, i \square konstante

$\omega = X$

$\mathcal{P} = \{X \rightarrow F + [[X] - X] - F[-FX] + X, F \rightarrow FF\}$

F i dalje znači crtanje dužine. X se ne crta, već služi evoluciji krivulje biljke. Zgrade kontekstno pamte vrijednosti pozicije „kornjače“ i kut smjera njezina kretanja te ih nakon nailaska na zatvorenu zagradu vraćaju na vrijednosti prije nailaska na pripadajuću otvorenu zagradu. Znak $+$ sada znači rotaciju ulijevo za 25° , a $-$ rotaciju udesno za 25° .

Ručno generiranje kôda biljke kao pripreme za crtanje ovdje bi već bilo zamorno i podložno pogreškama. Pomaže mali

ulomak kôda u jeziku Python, kao na slici (u okruţju Anaconda/ Jupyter). Vidimo da biljka raste vrlo brzo!

```

jupyter L-sustav: kod fraktalne biljke
Python 3 (ipykernel)
File Edit View Insert Cell Kernel Widgets Help Trusted Python 3 (ipykernel)
Run Code

In [27]: 1 def generirajKodBiljke(n, kod='[X]'):
          2     for _ in range(n):
          3         # pravilo/produkcija/aksiom #2
          4         kod = kod.replace('F', 'FF')
          5         # pravilo/produkcija/aksiom #1
          6         kod = kod.replace('X', 'F-[X]+X]+F[+FX]-X')
          7         print(kod)
          8

In [28]: 1 generirajKodBiljke(1)
          2
          3 [F-[X]+X]+F[+FX]-X]


In [29]: 1 generirajKodBiljke(2)
          2
          3 [F-[X]+X]+F[+FX]-X]
          4 [FF-[F-[X]+X]+F[+FX]-X]+F-[X]+X]+F[+FX]-X]+FF[+FFF-[X]+X]+F[+FX]-X]
          5 -F-[X]+X]+F[+FX]-X]

In [30]: 1 generirajKodBiljke(3)
          2
          3 [F-[X]+X]+F[+FX]-X]
          4 [FF-[F-[X]+X]+F[+FX]-X]+F-[X]+X]+F[+FX]-X]+FF[+FFF-[X]+X]+F[+FX]-X]
          5 -F-[X]+X]+F[+FX]-X]
          6 [FFFF-[FFF-[F-[X]+X]+F[+FX]-X]+F-[X]+X]+F[+FX]-X]+FF[+FFF-[X]+X]+F
          7 [+FX]-X]-F-[X]+X]+F[+FX]-X]+FF-[F-[X]+X]+F[+FX]-X]+F-[X]+X]+F[+FX]-
          8 X]+FF[+FFF-[X]+X]+F[+FX]-X]-F-[X]+X]+F[+FX]-X]+FFFF[+FFFFF-[F-[X]+
          9 X]+F[+FX]-X]+F-[X]+X]+F[+FX]-X]+FF[+FFF-[X]+X]+F[+FX]-X]-F-[X]+X]+F
         10 [+FX]-X]-FF-[F-[X]+X]+F[+FX]-X]+F-[X]+X]+F[+FX]-X]+FF[+FFF-[X]+X]+F
         11 [+FX]-X]-F-[X]+X]+F[+FX]-X]
    
```

SLIKA 4-21: L-sustav: kôd fraktalne biljke.

Ovdje prestaje naše druţenje s formalnim gramatikama u obliĉju L-sustava, drţeći se stare izreke „slika vrijedi tisuću rijeĉi“.⁹⁹ Naslovi ispod slika su autorovi.

⁹⁹ Razvoj umjetne inteligencije vodi nas njezinu obratu, „rijeĉ vrijedi tisuću slika“. Prošećimo nakratko od L_biljke do L_urbane_promenade!



SLIKA 4-22: Početni segment zmajeve krivulje generirane L -sustavom.

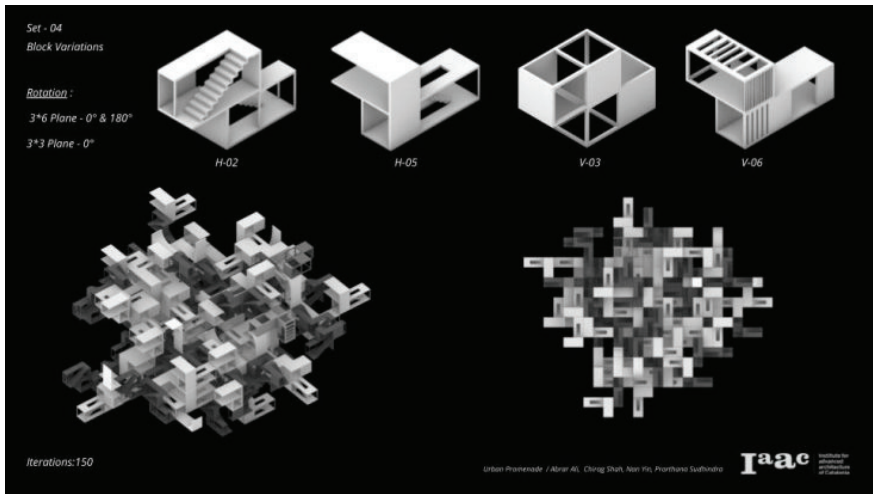


SLIKA 4-23: L -biljka.

Izvor: <https://martinmcbride.org/post/fractals/l-systems-trees/>.



SLIKA 4-24: Špageti L-ognese.
Izvor: <https://parametrichouse.com/l-system/>



SLIKA 4-25: Urbana promenada — 3D L-gramatika.
Izvor: <https://www.iaacblog.com/programs/urban-promenade-architectural-machines/>



SLIKA 4-26: Urbana promenada, 3D model.

Izvor: <https://www.iaacblog.com/programs/urban-promenade-architectural-machines/>

Regularni izrazi

Regularni izrazi predstavljaju obrasce strukture teksta od interesa za različite potrebe njegove obrade. Naziv dolazi iz formalne teorije jezika kojom se čitatelj za potrebe njihove primjene ne mora ni mrvicu zamarati. U engleskoj stručnoj terminologiji koristi se skraćenica *regex*. I njih se može smatrati jednom izvedbom formalnih gramatika, ali zbog njihovih specifičnosti izlažemo ih zasebno.

Regularni izrazi prožimlju sve segmente informacijskih tehnologija. Nalazimo ih ugrađene u operacijske sustave računala (UNIX,...), programske jezike, među njima specifično razvijene za procesiranje regularnih izraza, poput jezika Perl, ili one koji ih implementiraju kao vanjske module/biblioteke/packages, poput jezika Python, JavaScript, mnogih inačica jezika Prolog, kao i samostojeće

aplikacije. Moglo bi se reći da su regularni izrazi za tekst isto što i strukturirani jezici upita za relacijske baze podataka, kao što je SQL.

Literatura na temu regularnih izraza prebogata je i kreće se u rasponu od knjiga, članaka, priručnika za specifične alate i biblioteke funkcija, prezentacija (uključujući i one na kanalima kao što je YouTube) te golemog i raznolikog mnoštva ulomaka programskog kôda u gotovo svim programskim jezicima.

Među knjigama novijeg datuma izdvajamo *početnicu* (Watt, 2005), koja broji preko 700 stranica (sic!), zatim *uvod* (Fitzgerald, 2012), *kuharicu* (Goyvaerts i Levithan, 2012), te na kraju *knjigu zagonetki* (Mertz, 2023), zanimljivu i po tome što je autor konstrukcije regularnih izraza koje je sam razvijao kao upite postavljao i sustavu opće umjetne inteligencije ChatGPT. Iz predloženih rješenja autor je zaključio, sa čime bi se i autor ovog teksta priklonio, da je (trenutačno) ChatGPT s jedne strane vrlo pametan, a s druge (intelektualno) prilično *naivan*¹⁰⁰.

Prilikom ugradnje regularnih izraza u pojedinačne programske jezike morala je biti poštivana sintaksa izvornog jezika, slijedom čega je nastao cijeli niz *dijalekata* regularnih izraza, što je unekoliko otegotna okonost u smislu njihova usvajanja i korištenja. Pomažu samostojeće aplikacije kao što su RegexBuddy ili Regex 101 (Web-aplikacija) i brojne slične, koje omogućuju biranje dijalekta i nude generiranje kôda oblikovanog regularnog izraza u izabranom programskom jeziku (JavaScript, Python,...).

Glavni problem glede usvajanja regularnih izraza i njihova

¹⁰⁰ Da budemo „politički“ korektni.

korištenja je izuzetno bogata i sofisticirana semantika, s mnoštvom nijansi.

Ovo su neki¹⁰¹ od problema prikladnih za rješavanje korištenjem regularnih izraza:

- Pronalaženje određenog segmenta teksta i njegova zamjena drugim (potraži/zamijeni).
- Pronalaženje datoteka u mapama operacijskog sustava računala.
- Pretraživanje teksta datoteka.
- Provjera unosa podataka u podatkovna polja digitalnih obrazaca različitih aplikacija.
- Ekstrakcija korisnih podataka na Web-stranicama uz pomoć njihovih pretraživača.
- *Struganje*¹⁰² podataka s WEB-stranica.
- Restrukturiranje¹⁰³ (preoblikovanje) podataka u odgovarajući oblik za daljnju obradu.
- Analiza genoma.

Gramatika regularnih izraza

Regularni izrazi moraju biti strukturirani slijedom određenih pravila, jer samo tako mogu osigurati željenu strukturu obrazaca teksta koji pretražujemo ili stvaramo.

Ponajprije recimo da većina znakova gramatike regularnih izraza predstavlja same sebe, osim specijalno rezerviranih znakova

¹⁰¹ Izostavit ćemo probleme koji se tiču strukturiranja te unutarnje i vanjske analize programskih jezika i u njima pisanih programa.

¹⁰² Engl. *scrapping*. Moglo bi se reći i *češljanje*, odnosno *grebanje* podataka ...

¹⁰³ U engleskoj terminologiji često se koristi pojam *data wrangling*, što bi se moglo prevesti i kao *trvenje*, ili, kolkvijalno, *gombanje* s podacima.

koje zovemo *metaznakovi*. To su [] / ^ \$. | ? * + () { }¹⁰⁴. Ako ih se koristi kao obične znakove mora im prethoditi znak \¹⁰⁵.

Svi znakovi koje regularni izrazi koriste podijeljeni su u nekoliko klasa, među kojima su:

- Obični znakovi i njihovi nizovi—predstavljaju sami sebe.
 - [abc.] Uključuje samo specificirane znakove, tj. mala slova, 'a','b','c' i ''
 - [a-z] Uključuje sva mala slova od a do z.
 - [^az] Uključuje sve znakove osim a i z (znak ^ predstavlja znak isključivanja (negacije)).
 - \w Uključuje sva velika i mala slova te znamenke.
 - \d Uključuje znamenke 0-9
 - \W Komplement od \w
 - \D Komplement od \d (znak nije znamenka)
- Sidra—označavaju specifične lokacije u tekstu (početak, kraj,...).
 - ^ Označava (pored isključivanja/negacije) početak riječi..
 - \$ Označava kraj riječi.
 - \b Označava početak i kraj riječi koje čine mala i velika slova.
 - \A Pogađa početak teksta.
 - \Z Pogađa kraj teksta do oznake za novi redak.
 - \z Pogađa kraj teksta.
 - \G Pogađa tekst na zadanoj poziciji, pos().
 - \p{...} Zadaje klasu znakova prema standardu Unicode.
 - \P{...} Isključuje klasu znakova prema standardu Unicode.
- Metaznakovi—služe „vanjskom“ oblikovanju regularnih izraza
 - ^ Označava početak riječi (niza znakova).
 - \$ Označava kraj riječi.
 - .

¹⁰⁴ Čitamo ih kao pojedinačne znakove pa zarez nije potreban.

¹⁰⁵ Obrnuta kosa crta (engl. *backslash*).

*	Znak ili grupu znakova koji mu prethode "pogađa" (engl. match) 0 ili više puta.
+	Znak ili grupu znakova koji mu prethode pogađa (engl. match) 1 ili više puta.
?	Zamjenjuje (predstavlja ekvivalent) bilo kojeg pojedinačnog znaka.
()	Služi grupiranju.
\	Specijalni znak koji ga slijedi pretvara u obični.
[]	Reprezentira skup znakova.
{}	Koristi se za zadavanje broja ponavljanja znaka ili grupe znakova koji mu prethode.

- Kvantifikatori—određuju „brojno stanje“ znakova u svom dosegu.

a?	Provjerava nastupa li u tekstu slovo 'a' 0 ili 1 puta.
a*	Provjerava nastupa li u tekstu slovo 'a' 0 ili više puta.
a{2, 6}	Provjerava nastupa li u tekstu slovo 'a' 2 do 6 puta.
a{2, }	Provjerava nastupa li u tekstu slovo 'a' 2 ili više puta.
a{2}	Provjerava nastupa li u tekstu slovo 'a' točno 2 puta.

- Modifikatori—unose promjene u tekst.

\g	Zamjenjuje sve nastupe dane riječi u tekstu.
\gc	Omogućuje nastavak pretraživanja teksta nakon što \g ne uspije.
\s	Tekst na koji se odnosi tretira kao jedan redak.
i	Isključuje razlikovanje malih i velikih slova.
\x	Zanemaruje sve bjeline (razmak, TAB,...).

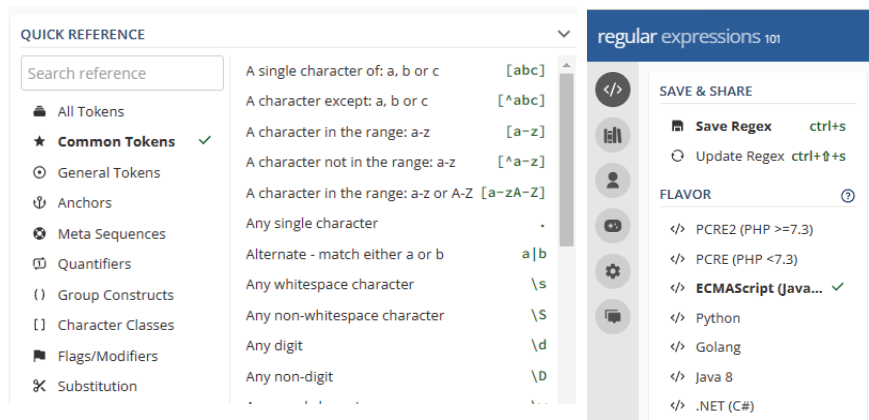
• • •

Jedini način stjecanja vještine u radu s regularnim izrazima jest dugotrajno vježbanje u rješavanju raznovrsnih problema. Za početak tome je vrlo primjerena netom spomenuta Web-aplikacija `regex101` (<https://regex101.com/>).


`Regex101` nudi sažet i vrlo pregeledan priručnik za rad s regularnim izrazima, izbor između više dijalekata i programskih jezika za njihovu implementaciju, okvir za upisivanje i testiranje

izraza, okvir za objašnjavanje generiranja izraza sukladno njihovom zapisu te okvir za otklanjanje pogrešaka.

Sljedeće slike redom prikazuju dijelove sučelja programa `regex101`, regularni izraz za pronalaženje svih višekratnih nastupa svih riječi u tekstu i rezultate testiranja, opet u programu `regex101`.



SLIKA 4-27: Elementi sučelja programa `regex101`.



SLIKA 4-28: Elementi sučelja programa `regex101`.

EXPLANATION

▼ / (?=\b(\w+)\b)(?:([\s\S]+\b\1\b)|(?<=\b\1\b[\s\S]*))\w+ / gi

- ▼ **Positive Lookahead** (?=\b(\w+)\b)
 - Assert that the Regex below matches
 - \b assert position at a word boundary: (^:\w|\w:\$|W:\w|\w:W)
 - ▼ **1st Capturing Group** (\w+)
 - ▼ \w matches any word character (equivalent to [a-zA-Z0-9_])
 - + matches the previous token between one and unlimited times, as many times as possible, giving back as needed (greedy)
 - \b assert position at a word boundary: (^:\w|\w:\$|W:\w|\w:W)
- ▼ **Non-capturing group** (?:([\s\S]+\b\1\b)|(?<=\b\1\b[\s\S]*))
 - ▼ **1st Alternative** (?=([\s\S]+\b\1\b))
 - ▼ **Positive Lookahead** (?=([\s\S]+\b\1\b))

SLIKA 4-29: Primjer regularnog izraza u programu `regex101`

Za kraj našeg druženja s regularnim izrazima dajemo jedan primjer raspoznavanja polustrukturiranih podataka regularnih izraza za potrebe njihove daljnje obrade.

Pretpostavimo da raspolažemo tiskanim izdanjem rječnika koji želimo ne samo digitalizirati, već ga preoblikovati u strukturu (digitalni rječnik, bazu podataka, strukturu hiperteksta,...) za potrebe daljnjeg korištenja.

U radu (Čubrilo i sur., 2001) istražen je problem automatskog preoblikovanja digitaliziranog tiskanog rječnika na primjeru rječnika *Oxford Dictionary of Modern English*, modeliranjem njegovih rječničkih jedinica u logičkom programskom jeziku drugog reda, Hilog.

Svaki rječnik u smislu strukturiranja svojih rječničkih jedi-

nica iskazuje određene specifičnosti, ali je metoda jednako dobra za svaki rječnik, kao i svaku drugu vrstu polustrukturiranog teksta.

Da je tekst polustrukturiran znači da je posredno, sukladno uzusima struke, građen prema određenim pravilima koja nisu svjesno formalizirana, ali su ipak zamjetna i mogu se određenim sredstvima formalizirati.

Za prepoznavanje strukture rječničkih jedinica ovdje koristimo regularne izraze. U rečenom radu, kao i ovdje, kao testnu rječničku jedinicu izabrali smo onu koja opisuje kontekst riječi **resort**.¹⁰⁶

resort (ri-zort) *v.* 1. to turn for help, to adopt as an expedient, *resorted to violence*. 2. to go, especially as a frequent or customary practice, *police watched the bars to he was known to resort*. —**resort** *n.* 1. an expedient, resorting to this, *compulsion is our only resort*; without resort to violence. 2. a place resorted to, a popular holiday place. □ **in the last resort**, when everything else has failed.

Primjećujemo da u strukturi rječničke jedinice pored „čistog“ teksta, sudjeluju i neka grafička obilježja pisma (*podebljano*, *kurziv*), kao i posebni grafički znakovi (— i □). Stoga je prilikom digitalizacije rječničkih jedinica kao format zapisa teksta potrebno izabrati neku izvedbu skriptnog jezika XML, što nije problem jer je, primjerice, koristi i Microsoft Word.

Kao i autor u (Mertz, 2023), iskušali smo sreću s ChatGPT-om i kroz cjelodnevnu prepisku, polazeći od jednostavnijih segmenata teksta, upućivanja na pogreške, opetovanog testiranja generiranih regularnih izraza i programskog kôda u jeziku Python, postići zadovoljavajući rezultat, uključujući i oblikovanje strukture podataka za potrebe kasnije obrade rječničkih jedinica.

Kao probni uzet je tekst "aaa (a-a-a) *v.* 1. aaa, bbb, ccc, ddd 2. eee, fff, ggg."

¹⁰⁶ Istu kao u spomenutom radu.

On ima strukturu segmenata rječničke jedinice **resort**, koji se uz određene modifikacije ponavljaju. Ideja je bila da se regularnim izrazom raspoznaju svi nastupi toga segmenta teksta u polaznoj rječničkoj jedinici te da se oni strukturiraju na sljedeći način:

```
[('aa', 'a-a', [('v.', [('r', ['bb', 'cc', 'dd.']), ('z', ['ee', 'ff.'])])])]
```

dakle, kao lista u jeziku Python, čiji svaki element je polje, čiji elementi su sama rječnička jedinica, zatim njezin izgovor, nakon čega slijedi lista lista, čiji elementi su polje na početku kojega dolazi vrsta riječi (ovdje samo glagol i imenica), zatim polje s oznakom rednog broja niza značenja polazne riječi te na kraju lista tih značenja, što u slučaju prvog segmenta rječničke jedinice **resort** izgleda ovako:

```
'resort', 'ri-zort', [('v.', [('r', ['to turn for help', 'to adopt as an expedient', 'resorted to violence.']), ('z', ['to go', 'especially as a fruequent or customary practice', 'police watched the bars to he was known to resort.'])])])]
```

Generirani kôd u jeziku Python izgleda ovako:

```
In [2]: 1 import re
2
3 # Define input string
4 input_string = "aa (a-a) v. 1. bb, cc, dd. 2. ee, ff."
5
6 # Extracting the headword and the verb
7 match = re.match(r'(\w+)\s+(([\w-]+\s+)+)\s+(\w\.)', input_string)
8 headword = match.group(1)
9 verb = match.group(2)
10 pos = match.group(3)
11
12 # Extracting the verb senses
13 verb_senses = []
14 sense_matches = re.findall(r'(\d+)\s+(\w\.)\s+(.*)((?=\s\d+\.\$))', input_string)
15 for sense_match in sense_matches:
16     sense_num = sense_match[0]
17     sense_words = sense_match[1].split(", ")
18     verb_senses.append((sense_num, sense_words))
19
20 # Create output
21 output = [(headword, verb, [(pos, verb_senses)])]
22 print(output)
```

```
[('aa', 'a-a', [('v.', [('r', ['bb', 'cc', 'dd.']), ('z', ['ee', 'ff.'])])])]
```


Za segment teksta

```
input_string = 'aa (a-a) v. 1. bb, cc, dd 2. ee, ff. —xx n. 1. yy, zz 2. uu, vv.'
```

rezultat je bio sljedeći:

```
split_strings[0]: aa (a-a) v. 1. bb, cc, dd 2. ee, ff.  
match: <re.Match object; span=(0, 37), match='aa (a-a) v. 1. bb, cc, dd 2. ee, ff. '>  
headword1: aa  
pronunciation1: a-a  
dictionary1: [('v', []), ('1', ['bb', 'cc', 'dd']), ('2', ['ee']), ('ff', [])]  
split_strings[1]: xx n. 1. yy, zz 2. uu, vv.  
match: <re.Match object; span=(0, 26), match='xx n. 1. yy, zz 2. uu, vv.'>  
headword2: xx  
pronunciation2: None  
dictionary2: [('n', []), ('1', ['yy', 'zz']), ('2', ['uu']), ('vv', [])]
```

Stavke `dictionary1` i `dictionary2` predstavljaju valjano raspoznate i valjano strukturiranu rječničku jedinicu (gotovo). Modificirani programski kôd predugačak je da bismo ga ovdje navodili.

Logička strana umjetne inteligencije

Kroz prethodna izlaganja u skromnoj smo mjeri izložili neke primjene statističkih metoda istraživanja u domeni (digitalne) humanistike, ali i u širem kontekstu podatkovne znanosti i umjetne inteligencije. Red je da nešto više kažemo i o njihovoj logičkoj strani. Za te potrebe autor od samoga sebe posuđuje, često prilagođene, dijelove izlaganja njegove „stare“ (izuzmemo li kvalitetu ondašnjeg računalnog sloga, još uvijek jednako dobre) knjige (Čubrilo, 1989) te dijela materijala knjige u nastajanju na temu simboličke logike i njezinih primjena.

Logika¹⁰⁷ je predmet izučavanja od pradavnih vremena do novijeg doba, najčešće u kontekstu filozofije (Sokrat, Aristotel,

¹⁰⁷ Pojam *logika* ovdje koristimo i kao rodnu imenicu, s obzirom da je primjerenije govoriti o vrlo raznovrsnom mnoštvu pojedinih tipova (formalnih) logika, razvijenih prema određenim kriterijima i za specifične potrebe istraživanja, odnosno primjene.

Platon,...). Čitatelj je tijekom svojega obrazovanja, ali i kroz stjecanje opće kulture, vrlo izgledno čuo za Aristotelove silogizme, obrasce logičke dedukcije¹⁰⁸ s elementima pristupa istoj na način suvremene simboličke logike¹⁰⁹.

Jedan od iskaza suvremenog pristupa znanstvenih teorija jest njihova aksiomatizacija, tj. svođenje na niz temeljnih objekata, njihovih elementarnih obilježja (često na razini intuicije) i njihovoj daljnjoj izgradnji metodama logičke dedukcije.

Povijesno nije posve sigurno je li Euklidova geometrija baš bila prva aksiomatska teorija u suvremenom smislu značenja toga pojma, ali je zasigurno tijekom, sada već i tisućljeća, ostala najpoznatijom. Izložena je u trinaest svezaka djela *Elementi*, danas poznata i kao elementarna geometrija, koju je čitatelj neizbježno sreo tijekom svojega obrazovanja¹¹⁰. Tijekom vremena doživjela je više od tisuću tiskanih izdanja¹¹¹, često komentiranih od strane prevoditelja, na mnoštvu jezika.

¹⁰⁸ logičkog izvoda, logičkog zaključivanja

¹⁰⁹ Poznata i kao *formalna*, odnosno *matematička* logika.

¹¹⁰ **Svi zasigurno pamtimo Arhimedov poučak, neki možda i Thalesov (svaki kut nad obodom promjera kružnice je pravi kut),...**

¹¹¹ **Prvo tiskano izdanje objavio je 1482 izdavač Erhardt Ratdolt u Venciji**



SLIKA 4-30: Stranica *Elementa* iz Ratdoltova izdanja iz 1482. g.

Euklidova ideja bila je, kako je već natuknuto, sve do njegova vremena¹¹² poznato geometrijsko (dijelom i aritmetičko) znanje svesti na mali broj temeljnih načela (aksioma), u primjeni na nekoliko tipova elementarnih, intuitivno jasnih geometrijskih objekata (točaka, dužina, pravaca, ravnina,...) i zatim sustavno izvoditi kako poznate poučke (teoreme) poput spomenutih, a zatim i nove.

Euklidova aksiomatizacija elementarne geometrije suvremene rigorozne zahtjeve u tome pogledu ne zadovoljava. Na suvre-

¹¹² Smatra se da su neki svesci *Elementa* kompilacije ranijih radova autora kao što su Arimed, Eudoks, i drugi, što Euklidove zasluge ne umanjuje ni na koji način.

meni način aksiomatizirao ju je David Hilbert¹¹³, poznati njemački matematičar i logičar koji je živio na prijelomu devetnaestog i dvadesetog stoljeća.

Naravno, u svoje *Elemente* Euklid nije ugradio i formalizaciju same logičke dedukcije. Logiku našu svagdanju koristio je kao *vanjski alat*, tj. kao neku vrstu *metateorije*¹¹⁴.

Pored same vrijednosti za geometriju, dijelom i aritmetiku, *Elementi* su utjecali i na razvoj drugih područja znanosti (opća ideja aksiomatizacije i aksiomatskih teorija) i tehnologije (arhitektura, strojarstvo,...).


U kontekstu Euklidove geometrije uspostavljena su najprije konkretna a onda i opća pitanja konzistentnosti (neproturječnosti), potpunosti, jesu li aksiomi dovoljni za izvođenje svih poučaka, (postojećih i budućih), jesu li aksiomi međusobno zavisni (pa se neki mogu ukloniti, a preostali će generirati istovjetan skup poučaka).

Potonje je iznjedrilo nove tipove geometrija, tzv. *neeuklidske geometrije*. Naime, aksiom o paralelama (kroz točku izvan pravca prolazi njemu samo jedan paralelan pravac) činio se mnogim proučavateljima Euklidove geometrije tijekom povijesti izlišnim te su ga kao poučak nastojali izvesti iz preostalih aksioma. Kada

¹¹³ Poznat i po. tzv. *Hilbertovim problemima*, njih 23, od kojih je 10 izložio na kongresu matematičara 1900. g. u Francuskoj. U to doba svi neriješeni (a neki su poput Riemannove i Goldbachove hipoteze takvima ostali i do danas), tijekom vremena su riješeni te su općenito imali velik utjecaj na razvoj matematike i ne samo nje.

¹¹⁴ Vrlo jezgrovito objašnjenje za *meta* izrekao je nesvjesno jedan dječčić vrtičke dobi kojega je prije nešto godina u jednom zagrebačkom vrtiću teta novinar-ka, povodom Dana hrane, upitala **za što je dobra svinja**. Dječak je nabrajao (priječavamo otprilike, po sjećanju): dlaka je dobra za četke, koža za cipele, meso za kobasice, špek za čvarke, a **ime** (svinjo jedna!) **dobro je za psovanje!**

to nije uspijevalo, aksiom je negiran, za što su postojale dvije mogućnosti: nijedan ili beskonačno mnogo pravaca paralelnih s danim pravcem kroz točku izvan njega) i izvođene su njegove posljedice (poučci), s nadom da će u jednom trenutku biti izvedena dva koja jedan drugom proturiječe. Tek kad ni od toga nije bilo ništa, sazrela je svijest o tome da svaka od preostalih dviju verzija aksioma o paralelama rezultira drugom geometrijom, jednako konzistentnom, jer su za svaku pronađeni modeli.



SLIKA 4-31: Pseudosfera-model hiperboličke geometrije.

(preuzeto s poveznice <https://ibmathsresources.com/2015/05/10/hyperbolic-geometry/>)

Geometrija koja zahtijeva da točkom izvan pravca prolazi njemu beskonačno mnogo paralelnih pravaca poznata je kao *hiperbolička geometrija* ili *geometrija Lobačevskoga*, po ruskom matematičaru N. I. Lobačevskom (1792-1856).

Projekcijom pseudosfere na zatvoreni krug na spoju

dvaju „čunjeva“ nastaje tzv Poincaréov¹¹⁵ disc, koji je nizozemski slikar Max Escher iskoristio za potrebe svojih slikarskih kreacija. O Escheru i njegovim slikama, u kontekstu još dvojice velikana znanosti i umjetnosti, Gödela i Bacha, puno se može doznati iz knjige D. R. Hofstadtera: *GÖDEL, ESCHER, BACH: The eternal golden braid*, Basic Books, 1999.




SLIKA 4-32: Escherova slika koja poštuje strukturu Poincareova diska.

Geometrija koja zahtijeva da točkom izvan pravca ne prolazi ni jedan njemu paralelan pravac poznata je kao *eliptička geometrija*.

Kao njezin najjednostavniji model može se uzeti trodimenzionalna sfera na kojoj „pravce“¹¹⁶ predstavljaju kružnice sa središtem u središtu sfere, kao na sljedećoj slici.

¹¹⁵ Henri Poincaré (1854-1912), poznati francuski matematičar.


¹¹⁶ Kad novu geometriju prihvatimo kao nezavisnu od Euklidove, navodnike možemo slobodno zaboraviti.



SLIKA 4-33: Trodimenzionalna sfera kao model eliptičke geometrije.

Jasno, čitatelj se pita koja od sada već tri geometrije je mjerodavna za stvarni život. Točnije, znajući da je Euklidova nepobitno mjerodavna, pitamo se kakva je vajda od preostalih dviju. Ne ulazeći u detalje, recimo samo da je hiperbolička geometrija „praktična“ u svemirskim razmjerima i da je kao naručena došla Einsteinovoj teoriji relativnosti, ali je uistinu praktična i u tzv. *hiperboličkim igrama*.

O mnogima, poput hiperboličkog sudokua, hiperboličkog tetrisa, itd., čitatelj može doznati počevši poveznicom <https://zenorogue.medium.com/non-euclidean-geometry-and-games-fb46989320d4>.



SLIKA 4-34: Ekran igre *Hiperbolički sudoku*.

Što se tiče sferne geometrije, ona se primjerice, masovno koristi za potrebe satelitskih komunikacija.

Ovaj prikaz geometrija, počevši od Euklidove, pored njihove neizmjerne važnosti samih po sebi, imao je zadaću čitatelja pripremiti za upoznavanje sa simboličkom logikom kao formalnim sustavom, kako je uostalom već ranije i rečeno, od iznimne važnosti za cijeli sklop informacijskih tehnologija, uključujući i područje umjetne inteligencije.

Sustavi simboličke logike

Na početku, prije negoli se pozabavimo izlaganju nekih elemenata simboličke logike, tek u tolikoj mjeri da čitatelj osjeti što se u njoj „kuha“, propitajmo njezinu praktičnu upotrebu u kontekstu informacijskih tehnologija.

Da bi simbolička logika bila djelatna, njezin glavni posao, a to je *logička dedukcija*, mora na ovaj ili onaj način biti *automatizirana* te kao takva ugrađena u programske jezike i alate. U današnjem smislu to je slučaj najkasnije od ranih sedamdesetih prošlog stoljeća, iako je nekih skromnijih pokušaja u tome smislu bivalo i ranije. Naime, u to vrijeme R. Kowalski i A. Colmerauer, oslanjajući se na ranije radove G. Fregea, T. Skolema, A. Horna, i drugih logičara, utvrđuju da jedan fragment tzv. *računa predikata prvog reda*, o kojemu će vrlo površno biti riječi nešto kasnije, točnije, fragment *Hornovih* (ili *hornovskih*) *klauzula* (logičkih formula specijalne strukture) predstavlja punokrvni programski jezik, što će reći da simulira tzv. *univerzalni Turingov stroj*, o čemu dalje zboriti nećemo. Nešto kasnije pridružio im se i D. Warren svojim apstraktnim strojem (WAM-Warren Abstract Machine) kojim je postavio memorijsku strukturu i naredbe najniže razine za programsku realizaciju logičkih programskih jezika. Rodonačelnik bujice kasnijih izvedbi na svim strojnim platformama i pod svim operacijskim sustavima jest logički programski jezik PROLOG, od PROgramming in LOGic). U moru izvedbi neke od najpoznatijih su BProlog, GNU Prolog, LPA-PROLOG, Sicstus Prolog, SWI-Prolog, Visual Prolog, XSB Prolog, da dalje ne nabrajamo. Većina ih je besplatna, a vrhunske komercijalne izvedbe, kao što je, recimo Visual Prolog,

koji u sebi, pored paradigme logičkog programiranja, ujedinjuje i proceduralno te objektno orijentirano programiranje, uz vizualno oblikovanje grafičkih elemenata aplikacija, može se dobiti za 100€.

Za jezik Prolog postoji i ISO standard, što ga čini vrlo stabilnim i pouzdanim. Dva dodatna obilježja Prologa su inherentna mogućnost *metaprogramiranja* (i programi su *samo podaci*) i jednoznačna semantika (pjesnik je htio reći točno ono što je i napisao¹¹⁷).

Programiranje u logičkim programskim jezicima u odnosu na klasične, proceduralne, razlikuje se po tome što se njima ne naređuje *kako* nešto napraviti, već *što* napraviti. Za *kako* brine pozadinski deduktivni mehanizam, zasnovan uglavnom na pravilu logičkog izvoda poznatom kao *pravilo rezolucije*, uz *negaciju kao konačan neuspjeh*, koje ćemo uskoro upoznati.

Temeljno obilježje logičkih programskih jezika jest *rekurzija*, tj. pozivanje *naredbi*, koje se u slučaju Prologa zovu *klauzule*, na samih sebe.

Svaki programski jezik, pa tako i Prolog, ima skup ugrađenih *naredbi* (ovdje *predikata*), kao i ugrađene *strukture podataka*. Dvije glavne struktura podataka u Prologu su *lista* (uređen skup elemenata) i *string* (niz znakova kao cjelina).

Za usporedbu izlažemo algoritam za računanje zadanoj permutaciji inverzne permutacije¹¹⁸, sličan objavljenom u prvom

¹¹⁷ Kad bi samo tako bilo i sa zakonima,...

¹¹⁸ Prvi autorov program, „napisan“ je na bušenim karticama u jeziku FORTRAN kao dio ispita iz kolegija Kibernetika na Matematičkom odjelu zagrebačkog PMF-a i „protjeran“ kroz računalu na mladom SRC-u, još vrtičke dobi. Prvi pokušaj nije uspio jer je, kako se ispostavilo, kup bušenih kartica bio posložen točno suprotno od valjanoga. Cijela „operacija“ trajala je mjesec dana, a dragocjeni *listing* u međuvremenu je zagubljen.

svesku, *Fundamental Algorithms*, Knuthove serije knjiga *The Art of Computer Programming*, posvećene isključivo strukturama podataka i algoritmima, namijenjen ilustriranju statističkih mjera složenosti algoritama.

Pretpostavljamo da je čitatelj s pojmom permutacije već upoznat. Permutacije možemo slagati ili komponirati, kao u sljedećem primjeru:

PRIMJER 4-3: Izračunati kompoziciju permutacija:

$$\alpha = (2\ 4\ 1\ 5\ 3) \text{ i } \beta = (3\ 5\ 1\ 4\ 2).$$

Ovdje su α i β skraćeni zapisi, jer zapravo predstavljaju preslikavanja:

$$\alpha = \begin{pmatrix} 1 & 2 & 3 & 4 & 5 \\ 2 & 4 & 1 & 5 & 3 \end{pmatrix}, \text{ tj., } 1 \rightarrow 2, 2 \rightarrow 4, \dots, 5 \rightarrow 3, \text{ odnosno}$$

$$\beta = \begin{pmatrix} 1 & 2 & 3 & 4 & 5 \\ 3 & 5 & 1 & 4 & 2 \end{pmatrix}, \text{ tj., } 1 \rightarrow 3, 2 \rightarrow 5, \dots, 5 \rightarrow 2.$$

Kompozicija $(\beta \circ \alpha)$ sada se definira ovako: prvo α , zatim β :


$$\begin{array}{c} \overbrace{1 \rightarrow 2}^{\alpha} \\ \underbrace{\quad \quad \quad}_{\beta} \\ \underbrace{\quad \quad \quad}_{\beta \circ \alpha: 1 \rightarrow 5} \end{array}$$

Rezultat je $(\beta \circ \alpha) = (5\ 4\ 3\ 2\ 1)$.

Inverzna permutacija danoj permutaciji je ona koja u kompoziciji s polaznom daje permutaciju-identitet, tj. $(1\ 2\ 3\ 4\ 5)$ u ovom slučaju. Za permutaciju α , lako ju je izračunati; to je permutacija $\alpha^{-1} = (3\ 1\ 5\ 2\ 4)$. Redom izlazi: $1 \rightarrow 2 \rightarrow 1$, $2 \rightarrow 4 \rightarrow 2$, $3 \rightarrow 1 \rightarrow 3$, $4 \rightarrow 5 \rightarrow 4$, $5 \rightarrow 3 \rightarrow 5$, tj. $1 \rightarrow 3$, $2 \rightarrow 1$, $3 \rightarrow 5$, $4 \rightarrow 2$, $5 \rightarrow 4$, tj.

(3 1 5 2 4).

Jedan od mnoštva mogućih realizacija algoritma u jeziku Python, u okruženju Anaconda/Jupyter je sljedeća:



The screenshot shows a Jupyter Notebook window titled "jupyter Inverzna permutacija - Knuth Last Checkpoint: Last Friday". The interface includes a menu bar (File, Edit, View, Insert, Cell, Kernel, Widgets, Help) and a toolbar with icons for file operations, navigation, and execution. The main area contains a code cell with the following Python code:


```
In [7]: 1 def inverzna_permutacija(Permutacija):
2         n = len(Permutacija)
3         Inverz = [0] * n
4         for i, x in enumerate(Permutacija):
5             Inverz[x - 1] = i + 1
6         return Inverz
7
8
9 #Primjer
10 Permutacija = [3, 1, 2, 5, 4]
11
12 Inverz = inverzna_permutacija(Permutacija)
13 print(Inverz)
14
```

Below the code cell, the output is displayed as:

```
[2, 3, 1, 5, 4]
```

Kako je algoritam iz knjige profesora Knutha prilagođen njegovom virtualnom stroju MIX i napisan u pripadajućem zbirnom programskom jeziku, nije ga uputno izvesti na doslovce jednak način. Recimo da je gornji samo dopola *à la* Knuth.

Algoritam je testiran na nekoliko jednostavnih permutacija, poput:



The screenshot shows a code cell with the following Python code:

```
In [8]: 1 Inverz = inverzna_permutacija([3, 6, 1, 5, 4,2])
2         print(Inverz)
```

Below the code cell, the output is displayed as:

```
[3, 6, 1, 5, 4, 2]
```

odnosno

```
In [9]: 1 Inverz = inverzna_permutacija([7,3, 1, 2, 6, 4,5])
        2 print(Inverz)
[3, 4, 2, 6, 7, 5, 1]
```


Jedinu sigurnost u valjan rad algoritma/programa općenito može pružiti njegova verifikacija u tome namijenjenim programskim jezicima i alatima kao što je Coq. To ipak nije tema ove knjige.

U slučaju Prologa, a ovdje koristimo mrežnu inačicu SWI Prologa, SWISH, ideja je oponašati definiciju inverzne permutacije na ranije viđeni način, ali u „ruhu“ Prologa. Bit će dosta na početku definirati „praznu“ polaznu inverznu permutaciju i zatim je postupno popunjavati elementima iz polazne permutacije na način da se na mjestu koje predstavlja indeks u inverznoj permutaciji upiše indeks koji pripada toj vrijednosti u polaznoj permutaciji. Primjerice, u permutaciji [3, 2, 5, 1, 4]: na trećem mjestu (indeks 3) stoji vrijednost 5. Stoga će na mjestu indeksa 5 u inverznoj permutaciji stajati 3. Spojimo li te dvije zamjene dobit ćemo $3 \rightarrow 5 \rightarrow 3$, tj. $3 \rightarrow 3$. Na taj će način kompozicija polazne i inverzne permutacije biti permutacija-identitet, što će reći da je konstrukcija inverzne permutacije valjana. Ostalo su „tehnički“ detalji. Prvo nekoliko testova, a zatim kôd:

 <code>inverzna([2,4,1,3],Inverz,4).</code>	 <code>inverzna([2,4,1,6,3,5],Inverz,6).</code>
Inverz = [3, 1, 4, 2]	Inverz = [3, 1, 5, 2, 6, 4]

 <code>inverzna([5,4,3,2,1],Inverz,5).</code>	 <code>inverzna([1,2,3,4,5],Inverz,5).</code>
Inverz = [5, 4, 3, 2, 1]	Inverz = [1, 2, 3, 4, 5]

Vidi se da su neke permutacije same sebi inverzi!


SWISH File Edit Examples Help

 Program +


```

1  inverzna(_,_,0):-!.
2
3  inverzna(Perm,Inverz,M):-
4      length(Perm,M),
5      length(Inverz,M),
6      maplist(sve_razlicite, Inverz),!,
7      zamjena(M,Perm,Inverz).
8
9  sve_razlicite(_).
10
11 zamjena(0,_,_):-!.
12
13 zamjena(I,Vrijednost, NovaVrijednost):-
14     nth1(I,Vrijednost,J),
15     nth1(J,NovaVrijednost,I),
16     I1 is I-1,
17     zamjena(I1,Vrijednost, NovaVrijednost).

```

Program ne predviđa unos duljine permutacije od strane korisnika, već ga on zadaje u samom upitu. Da se i to postigne, dovoljna je mala modifikacija kôda, ali bi ona ovdje „zamaglila“ njegovu suštinu, pa je to izostavljeno. Glavni predikati koji obavljaju posao su `nth1/3`, koji očitava vrijednosti elemenata u ulaznoj permutaciji i postavlja ih na pravo mjesto u inverznoj, zatim `length/2`, koji s jedne strane definira „praznu“ polaznu inverznu

permutaciju željene duljine, *maplist/2*, koji je popunjava anonimnim varijablama¹¹⁹ te zamjena/3, koja na kraju računa inverznu permutaciju. Ciljni predikat, *inverzna/2* samo orkestrira sve u jednu cjelinu.

A sada je došlo vrijeme da malo zavirimo u „kuhinju“ automatske dedukcije na primjeru klasičnog¹²⁰ računa sudova.

Elementi pristupa računu sudova kroz sintaksu

Kao i većini logičkih računa, i klasičnom računu sudova (u daljnjem izlaganju samo *račun sudova*) može se pristupiti kroz *sintaksu (teoriju izvoda)*, koja se bavi *formom*, odnosno kroz *semantiku*, koja se bavi *sadržajem*.

Bez obzira koji pristup izabrali, zajednički su im polazna abeceda i pravila gradnje sudova, koji zajedno čine gramatiku $\mathcal{G}(\text{RS})$ računa sudova. Ona zatim generira jezik $L(\text{RS})$ računa sudova kao skup sudova. Zbog boljeg strukturiranja izlaganje će biti nešto formalnije (numerirane definicije, poučci, formule,...), što čitatelja zasigurno neće smetati.

¹¹⁹ U prvoj verziji predikat *maplist* definiran je tako da sve anonimne varijable imaju istu „vrijednost“. Iz nekog razloga, umjesto da samo zamijeni vrijednost anonimne varijable na zadanoj poziciji nepopunjene inverzne permutacije, SWI Prolog zamijenio ih je sve, što smatramo njegovom sistemskom pogreškom. Stvar je spasio pomoćni predikat *sve_razlicite!*

¹²⁰ U današnje vrijeme poznat i kao Hilbertov račun sudova zbog njegove aksiomatizacije (ipak, jedne od mnogih) istoga.

DEFINICIJA 4-1: Abeceda \mathcal{A} jezika $L(\mathbf{RS})$ unija je sljedećih skupova simbola:

1. $A = \{P, Q, R, \dots\}$ — prebrojiv skup (simbola) atomarnih sudova (atoma), po potrebi s indeksima.
2. $\{\neg, \wedge, \vee, \rightarrow, \leftrightarrow\}$ — skup logičkih veznika, redom „ne“, „i“, „ili“, „povlači“ i „ekvivalentno“,
3. $\{(\, ,)\}$ — lijeva i desna zagrada.

Slijedi definicija suda:

DEFINICIJA 4-2:


1. Svaki atomarni sud je sud.
2. Ako je F sud, onda je to i $(\neg F)$.
3. Ako su F i G sudovi, onda su to i $(F \wedge G)$, $(F \vee G)$, $(F \rightarrow G)$ i $(F \leftrightarrow G)$.
4. Riječ u abecedi \mathcal{A} jezika $L(\mathbf{RS})$ je sud ako i samo ako je nastala uzastopnom primjenom nekih (možda i svih) od pravila 1) – 3) konačno mnogo puta.
5. Skup svih sudova građenih sukladno točkama 1) – 4) čini jezik računa sudova, $L(\mathbf{RS})$.

PRIMJER 4-4:

1. $((\neg P \rightarrow (\neg Q \rightarrow ((\neg R))))))$
2. $((P \wedge Q) \leftrightarrow (\neg((\neg P) \vee (\neg Q))))$
3. $((P \wedge (Q \vee R)) \leftrightarrow ((P \vee Q) \wedge (P \vee R)))$
4. $((P \wedge (Q \vee ((\neg P \vee R))))))$

$$5. ((\neg P) \rightarrow (P \rightarrow Q))$$

U smislu tipa strukture podataka sudovi predstavljaju binarna stabla, jednako kao i algebarski izrazi u standardnom (infiksnom) zapisu, a zagrade u oba slučaja služe nametanju strukture izraza suprotno prirodnom odnosu prioriteta (ili snage vezivanja) sudova logičkim veznicima, odnosno algebarskih izraza računskim operacijama (operatorima).



SLIKA 4-35: Stablo suda.

Broj zagrada u zapisu sudova može se reducirati slično načinu njihova reduciranja u zapisu algebarskih izraza.

Obrazac aksiomatizacije računa sudova jasan je iz prikaza Euklidove geometrije. Svrha joj je pomoću aksioma i pravila logičkog izvoda iz postojećih generirati nove sudove. Aksiomatizacija je mnogo. Jednu navodimo prema (Čubrilo, 1989).

Aksiomatizacija računa sudova

$$RS_1 \quad F \rightarrow (G \rightarrow F)$$

$$RS_2 \quad (F \rightarrow (G \rightarrow H)) \rightarrow ((F \rightarrow G) \rightarrow (F \rightarrow H))$$

$$RS_3 \quad (\neg F \rightarrow \neg G) \rightarrow (G \rightarrow F)$$

$$RS_{4)a) \quad (F \wedge G) \rightarrow F$$

$$RS_{4)b) \quad (F \wedge G) \rightarrow G$$

$$RS_5 \quad (H \rightarrow F) \rightarrow ((H \rightarrow G) \rightarrow (H \rightarrow (F \wedge G)))$$

$$RS_{6)a) \quad F \rightarrow (F \vee G)$$

$$RS_{6)b) \quad G \rightarrow (F \vee G)$$

$$RS_7 \quad (F \rightarrow H) \rightarrow ((G \rightarrow H) \rightarrow ((F \vee G) \rightarrow H))$$

Jedino pravilo izvoda je *modus ponens*; sud G logička je posljedica sudova $F \rightarrow G$ i F .

PRIMJER 4-5:

Sud $(P \wedge \neg P) \rightarrow (Q \rightarrow (P \wedge \neg P))$ je aksiom jer je nastao uvrštavanjem sudova $(P \wedge \neg P)$ i Q iz sheme aksioma RS_1 umjesto F , odnosno G .

DEFINICIJA 4-3:

Sud F kao logičku posljedicu skupa sudova Σ , u oznaci $\Sigma \vdash F$, definiramo kao niz sudova F_1, F_2, \dots, F_n , gdje je $F_n : F$, a svaki od sudova F_1, \dots, F_{n-1} je ili aksiom, element skupa Σ , ili je nastao primjenom pravila izvoda MP na neke ranije izvedene sudove.

Svaki sud izveden iz praznog skupa sudova Σ ($\phi \vdash F$ ili samo $\vdash F$) zovemo *teoremom* računa sudova.

PRIMJER 4-6: Za svaki sud F vrijedi $\vdash F \rightarrow F$.

Sukladno prethodnoj definiciji čini ga sljedeći niz sudova:

$$1) (F \rightarrow ((F \rightarrow F) \rightarrow F)) \rightarrow ((F \rightarrow (F \rightarrow F)) \rightarrow (F \rightarrow F))$$

(aksiom, dobiven iz sheme aksioma RS_2 uvrštavanjem $F \rightarrow F$ za G i G za H).

$$2) (F \rightarrow ((F \rightarrow F) \rightarrow F))$$

(aksiom, dobiven iz sheme aksioma RS_1 uvrštavanjem $F \rightarrow F$ za G)

$$3) ((F \rightarrow (F \rightarrow F)) \rightarrow (F \rightarrow F))$$

(sud, dobiven primjenom pravila MP na 1) i 2))

$$4) (F \rightarrow (F \rightarrow F))$$

(aksiom, dobiven iz sheme aksioma RS_1 uvrštavanjem F za G)

$$5) (F \rightarrow F)$$

(prema pravilu MP iz 3) i 4))

Za sud $F \rightarrow F$ *intuitivno*, na razini *sadržaja* (ako je F *istinit* onda je F *istinit*) shvaćamo da je trivijalno valjan pod svim uvjetima, tj. *interpretacijama*, tj. da je *tautologija*¹²¹, dok na razini *forme* do njega kao *teorema* nije posve jednostavno doći. Problem je *ugađanje* strukture binarnog stabla koja predstavlja sud u pravilo *modus*

¹²¹ Oba pojma pobliže ćemo uskoro definirati.

ponens. Nešto pomaže poučak (teorem) o dedukciji¹²² za račun sudova, ali za potrebe automatskog rješavanja logičkih problema na velikoj (industrijskoj) skali to ni izdaleka nije dovoljno¹²³.

POUČAK 4-I: (O DEDUKCIJI, J. HERBRAND, 1930):

Neka je Σ skup sudova i G i H bilo koja dva suda. Ako je ispunjeno $\Sigma \cup \{G\} \vdash H$, onda je ispunjeno i $\Sigma \vdash G \rightarrow H$.

Poučak o dedukciji izlažemo na sljedećem primjeru:

PRIMJER 4-7: Kakvi god da su sudovi F, G i H , vrijedi:

$\vdash (F \rightarrow G) \rightarrow ((G \rightarrow H) \rightarrow (F \rightarrow H))$.

Uzastopno primjenjujući poučak o dedukciji zaključujemo da je dovoljno dokazati sljedeće:

1) $\Sigma_1 = \{F \rightarrow G\} \vdash (G \rightarrow H) \rightarrow (F \rightarrow H)$, odnosno

2) $\Sigma_2 = \{F \rightarrow G, G \rightarrow H\} \vdash (F \rightarrow H)$, i na kraju

3) $\Sigma_3 = \{F \rightarrow G, G \rightarrow H, F\} \vdash H$.

4) $F \rightarrow G$ (pretpostavka, tj element iz Σ_3),

5) $G \rightarrow H$ (pretpostavka),

6) F (pretpostavka),

¹²² Strogo govoreći, bilo bi pravilnije reći *metapoučak* (metateorem), jer on o računu sudova govori izvan (iznad) njega.

¹²³ Na drugim, više manje negoli više, srodnim idejnim (formulacija logičkog računa) i izvedbenim (automatski deduktivni mehanizam) osnovama, postoje brojni sustavi automatske dedukcije (ponajviše) sintaktičkog tipa (Coq, THINKER, Lean, Agda,...)

7) G (po pravilu MP iz 1) i 3)),

8) H (po pravilu MP iz 2) i 4)).

Ovim završavamo naše bavljenje računom sudova *kroz formu*, tj. kroz aksiomatski pristup. Vraćamo mu se pristupom kroz sadržaj, tj. *semantiku*.

Elementi pristupa računu sudova kroz semantiku

Dva poučka računa sudova čiji se izvod može naći na mnoštvu mjesta, pa i u (Čubrilo, 1989) jesu:

$$\vdash \neg F \rightarrow (F \rightarrow G) \text{ i}$$

$$\vdash (F \rightarrow G) \rightarrow (\neg G \rightarrow \neg F).$$

Prvi se interpretira kao univerzalno pravilo logičkog zaključivanja *ex falso quodlibet* (*iz laži bilo što*¹²⁴), poznato još iz antičkih vremena. Ono kazuje da ako sud F nije istinit (tj. *ako je lažan*), onda iz njega slijedi bilo koji zaključak G .

Drugi se zove *obrat po kontrapoziciji* (sudova F i G).

$$\overbrace{(F \rightarrow G)}^{\text{kiša pada}} \rightarrow \overbrace{(\neg G \rightarrow \neg F)}^{\text{ulice su mokre}} \quad \overbrace{(\neg G \rightarrow \neg F)}^{\text{ulice nisu mokre}} \rightarrow \overbrace{(F \rightarrow G)}^{\text{kiša ne pada}}$$

S gornjom interpretacijom lako ćemo se složiti. Ona odgovara našem iskustvu. Autor zasigurno nije, a sumnjamo da je i čitatelj čuo za suprotan slučaj, tj. *da kiša pada i da su ulice suhe*.

Dakle, *semantika*, za razliku od *sintakse*, bavi se *značenjem* ili *interpretacijom* sudova, odnosno njihovom (ne)istinitošću u danoj interpretaciji, na što se onda vežu isti temeljni pojmovi koje smo sreli i u aksiomatskom pristupu, a to su pojam logičke poslje-

¹²⁴ Zlatni alat obmanjivanja.

dice i pojam logičkog izvoda.

Pojam interpretacije susrećemo i u uvriježenim sintagmama svakodnevnog govornog jezika, poput „čitanje između redaka”, ili, „što je pjesnik htio reći”. Prije negoli se pozabavimo semantikom računa sudova, dobro je prisjetiti se njezinih pojavnosti i u drugim područjima ljudskog djelovanja. Jedno takvo područje zasigurno je prevođenje s jednog govornog jezika na drugi. Današnji programi za, uvjetno rečeno, automatsko prevođenje između govornih jezika, iako vrlo uznapređovali, još uvijek su daleko od kvalitete prevođenja profesionalnih prevoditelja. Koliko je “ugađanje” semantike (smisla, sadržaja) zakučasta stvar, zorno pokazuje i jedan primjer teksta koji je autor svojevremeno dobio e-poštom i koji je očigledno nastao automatskim prevođenjem izvornog engleskog teksta na hrvatski jezik. Tekst govori sam za sebe, tako da smo se u njegovu tumačenju ograničili tek na minimum „lekture”, ističući uglavnom samo one riječi ili dijelove rečenica čiji neodgovarajući prijevod drastično izokreće smisao teksta do razine (tragi)komičnosti.

From:Dr. Kevin Brown [drbrownkevinkevin@msn.com]

Sent:9. lipnja 2009¹²⁵. 0:26

To:undisclosed-recipients:

Subject:OD Dr. Kevin

Poštovani Prijatelju,

Kako ste danas i obitelj? Nadam se dobro, ja sam Dr.kevin smeđa. Od Haledon, North West London, ovdje u Engleskoj. Ja radim za Natwest Bank Corporation London.

¹²⁵ Od tada puno se toga glede automatskog prevođenja dogodilo nabolje.

Pišem vam iz mog ureda, koja će biti od goleme koristi na oba od nas. U mom odjelu, kao pomoćnik upravitelja (Greater London Regional Office, otkrio sam jedan napušten zbroj¹²⁶ (☺) 12,5 milijuna dolara USA dolar (Dvanjest milijuna petsto tisuća Us dolara) u obzir da spada u jedan od naših inozemnih kupaca kasnu¹²⁷ (tj.☹)(☹), gospodin Thompson Morrison American Građanin koji je na žalost izgubio život u avion srušiti i Alaska Airlines Flight 261 koji pala na 31 sij 2000, uključujući i njegovu ženu i samo¹²⁸ (☹☹)(☹☹)) kćer.

Izbor kontaktiranja vam je pobudila iz zemljopisnih prirodi gdje živite, osobito s obzirom na starost od transakcije i povjerljivost ovdje. Sada naš bankovni je čekivanje za bilo koju od rodbine da dođe up za tvrdnju, ali nitko nije učinio to. Ja osobno je neuspješna u locirati i rodbine za 2 godine, ja tražiti vaš pristanak da vam predstaviti kao najbliži rođak / Hoće korisnika za pokojnika (☹☹)(☹☹)), tako da je prihod ovog računa u vrijednosti od 12,5 milijuna dolara može biti plaćeni za vas.

Ovo će biti isplaćeni ili dijeljen u ovim procentima, 60% na 40% mene i za tebe¹²⁹ (☹☹☹). Imam osigurano sve potrebne zakonske dokumente koji se mogu koristiti kopiju ove tvrdnje koje čine. Sve je to, ako je

¹²⁶ Zasigurno zagubljen iznos/sumu.

¹²⁷ Očigledno late, tj. preminuli.

¹²⁸ Očigledno *only*, tj. *jedinu* kćer. Kako je prevedeno, izgleda kao da je još netko iz obitelji trebao poginuti, ali nije, pa nam je kao malo žao?!

¹²⁹ Poštena podjela!

potrebno (!!)ispuniti u vašem imena u dokumentima i legalizirati ga u predvorju ovdje da vas kao legitiman korisnicama. Sve što je sada zahtijevaju Vašu possteni suradnju, povjerljivost i povjerenje nam omogućiti da se vidi kroz ovu transakciju. Garantiram vam da će ovo biti pogubljen (©)pod legitiman dogovoru koji će vas zaštititi od bilo kakve povrede na law.Please, pružaju mi je sljedeće: kao što smo 7 dana na vožnji preko. To je vrlo HITNO MOLIM.

1. Full: Ime
2. Vaša: Telefonski broj
3. Vaš kontakt adresa.
4. Starost:
5. Core Job / Zanimanje:
6. spol:
7. Vašu putovnicu:

Imajući otišao kroz metodički traži, JA odlučio je da Vam se u nadi da ćete naći zanimljive ovaj prijedlog. Molimo Vašu potvrdu na ovu poruku i naznakom vašeg interesa, ja ću vas opskrbiti s više informacija. Nastojati da javite mi svoju odluku, a ne držati me čeka.

Pozdravi,Dr.kevin smeđa

Neočekivana mjesta, na kojima se, uz valjano tumačenje, mogu pronaći razmatranja suštinskih odnosa i sustava suvremene znanosti, jesu basne, pripovijetke i druge vrste pisane predaje. Tako se, primjerice, cijeli zaplet Ezopove basne o lisici i rodi može tumačiti kao izraz nesklada između određenih algoritama i svjesno

im pridruženih struktura podataka, dok suštinu¹³⁰ odnosa između sintakse (teorije izvoda) i semantike (koja se bavi interpretacijama i istinom) formula logičkih računa, izvrsno dočarava narodna pripovijetka Nasrudin–Hodža i Francuz, koju ovdje u cijelosti prenosimo preme rečenom izvorniku.

NASRUDIN–HODŽA I FRANCUZ

Došao nekakav Francuz u Stambol i javio se u carski saraj. Car ga primio lijepo, a Francuz mu kaže da bi se poturčio, ako mu ko mogne misli pogoditi. Traži car gore dolje, ne može nikoga naći, ko bi mogao s tako učenijem čovjekom govoriti, a još manje, ko će mu misli pogoditi. Kaže mu neko za Nasrudin–hodžu; veli: Ako mu on ne pogodi, drugi niko ne može!

Brže car pošalje sluge po Nasrudina. Tražili su ga dugo, nigdje ga stići. A Nasrudin svaki bi dan uzjaho, pa išao nekud u Stambolu, kud on hoće, a taj dan pustio magarcu da ga nosi kud magarac hoće. Jedva u neko doba nađu ga carske sluge i kažu mu da ga car odmah zove k sebi. Nasrudin okrene magarca pa uprav carskom saraju. Gladan je kao vuk, jer vazdan nije ništa jeo, ko kad je išao za magarećom pameti; pa ga eto snađe još veći belaj, jer zna da nije dobra, čim ga car zove preda se. Ele kako mu nedrago, sjaše sa magarca, priveže ga za avlinska vrata, pa pred cara. Kaže mu car, što je i kako je, i zašto ga je zvao, a Nasrudin se stade pravdati, da ne zna francuski govoriti; no carski ljudi navale na nj, makar išaretom da govori s Francuzom, i tako ga skolesaju. Uđe Nasrudin u jednu odaju i sjede na minderluk. Dok eto ti Francuza i sjede prema njemu. Francuz pogleda Nasrudina, pa zaokruži

¹³⁰ Da naglasimo još jednom.

rukom ispred sebe poput kruga, a Nasrudin opet rukom kao da prisjeca krug na pola. Opet Francuz rukom iz sred onoga kruga sa uzdignutim prstima miče rukom nekoliko puta, a Nasredin opet rukom ozgor kao da što prosipa po onome krugu. Čudi se Francuz, pa poteže jaja iz džepa, a Nasrudin komadić sira, pa prema njemu. Skoči Francuz, pa upravo caru.

Pogodi, veli, sve što gođ sam mislio, i sad turči me kako gođ hoćeš!

— Kako to bi? Upita car.

— Eto kako: ja zaokružim ispred sebe, k'o velim: zemlja je okrugla. A on raspolovi, biva: polovina je voda. Ja opet rukom ozdo pokažem, kako iz zemlje raste svakojako bilje, a on opet rukom ozgor pokazuje, kako kiša pada i bez kiše ne može rasti. Ja potegnem iz džepa jaje, misleći ovako: evo ovakva je zemlja, a on pokaza komad sira: taka je kad snijeg pada.

Iziđe Francuz, a car zovne Nasrudina, pa ga pofali i upita, kako pogodi sve, što je Francuz mislio.

— To je bar bilo lasno, veli Nasrudin.

— On zaokruži ispred sebe, ko veli: imam dobru pogaču, a ja kako sam gladan jedva dočekam i prepolovim ispred sebe, mislim: pola meni, pola tebi. On opet učini rukom ozdo, kao kad kvrcu pilav, i veli: imam dobar pilav; a ja pokažem rukom ozgo, velim: zamasti, dobro zamasti! On pruži jaje, ko veli: evo, pa ćemo i ćimbur ispeći; a ja pokažem komad sira, velim: evo pa ćemo načiniti i omak.

Nasmija se car Nasrudinovoju mudrosti, lijepo ga obdari i otpusti, i od tada osta riječ: razumjeli se k'o Francuz i Nasrudin.

Iz Sarajeva

OBJAŠNJENJA: Hodža—muslimanski svećenik; Stambol—Carigrad; saraj—dvor, dvorac samo za mušku čeljad ili za goste; belaj—nesreća, bijeda; avlinska—dvorišna; išaretom—migom, namigujući; skolesaju—privole ga da je morao popustiti; minderluk—duž zida krevet sa mekom prostirkom na kome se sjedi; kvrca—rastresa; ćimbur—jelo od jaja i luka; omak—neko jelo; pilav—gusto kuhana riža.

Oba sudionika ove pripovijetke izvanjsko su događanje caru opisala na istovjetan način. Sve što se izvana događalo možemo shvatiti logičkim izvodom jednog te istog zaključka (Nasrudin—hodža pogodio je Francuzu misli) na razini sintakse nekakve formalne teorije pantomime. Međutim, svatko od njih imao je samo svoju (semantičku) interpretaciju izvanjskih događanja, a pripovijetka i jest smiješna upravo zbog velikih razlika među iskazanim interpretacijama rečenog događaja od strane njegovih sudionika.

Ova pripovijetka zapravo iskazuje redovno stanje u domeni logičkih računa i drugih aksiomatskih teorija. Aksiomatske teorije, kako je čitatelj zasigurno zaključio kroz prikaz Euklidove geometrije, nastaju apstrakcijom univerzalnih zakonitosti pojedinačnih domena znanja. Problem je, međutim, u tome da uspostavljeni aksiomatski sustav uvijek opisuje puno više od onoga što bismo možda željeli. Drugim riječima, svaka aksiomatska teorija, pored predmnijevanog (kanonskog) modela, čijom apstrakcijom je nastala, opisuje i mnoštvo drugih modela. Potonje zapravo znači da je naša intuicija u pogledu apstraktnih objekata, kao što su, primjerice, “svima znani” prirodni brojevi, vrlo nepouzdana.

Od korištenja istih ideja ne zazire ni suvremena medijska

komunikacija, koristeći ih, primjerice, u reklamne svrhe. Zgodan primjer je već podosta godina unatrag prikazivana TV-reklama za jedan poznati prašak za pranje rublja. Za potrebe ovog izlaganja dat ćemo joj naslov “Mama, oženit ću učiteljicu!”. U njoj đak-prvak dolazi iz škole kući i odmah s vrata, sav ozaren, mami obznanjuje svoju “životnu odluku”. Naime, on se ženi učiteljicom! Zatim slijedi insert u kojem se čuje kako đaćić mami objašnjava svoje viđenje razvoja “ženidbene situacije” (učiteljica ga dugo i zaljubljeno gleda, u jednom trenutku mu kaže: “Najbolje da ipak pitamo tvoju mamu”,...), dok uporedo promiču kadrovi na kojima se vidi kako učiteljica zapravo gleda bjelinu dječakove košulje, oprane dotičnim praškom za pranje (ovdje ga nećemo reklamirati), razmišlja o kojem prašku je riječ i zaključuje kako je za to najbolje pitati dječakovu mamu.

Prelazimo sada na detaljnije i formalnije izlaganje semantičkog pristupa računu sudova na putu prema učinkovitoj automatizaciji logičkog izvoda za nj.

DEFINICIJA 4-4: Neka je sud F sačinjen od atomarnih sudova P_1, P_2, \dots, P_n , na način iz Definicije 4-2. Pod interpretacijom suda F podrazumijevamo svaku funkciju $i\{P_1, P_2, \dots, P_n\} \mapsto \{0, 1\}$.

Vrijednosti $i(P_j)$ za svaki j zovemo *vrijednostima istinitosti*. Ako je $i(P_j) = 0$, kažemo da je sud F u interpretaciji i lažan, dok u suprotnom kažemo da je on u toj interpretaciji istinit.

Vrijednost istinitosti atomarnih sudova od kojih je sud F sačinjen, zajedno s logičkim veznicima pomoću kojih je sačinjen, jednoznačno određuje vrijednost istinitosti samog suda F . To po-

kazuju svima znane semantičke tablice¹³¹. One samo prenose našu intuiciju u pogledu logičkih veznika i njihova ponašanja u složenim sudovima.

a)	P	$\neg P$
	0	1
	1	0

b)	P	Q	$P \wedge Q$
	0	0	0
	0	1	0
	1	0	0
	1	1	1

c)	P	Q	$P \vee Q$
	0	0	0
	0	1	1
	1	0	1
	1	1	1

d)	P	Q	$P \rightarrow Q$
	0	0	1
	0	1	1
	1	0	0
	1	1	1

e)	P	Q	$P \leftrightarrow Q$
	0	0	0
	0	1	0
	1	0	0
	1	1	1

Svaki redak svake tablice daje jednu moguću interpretaciju suda F , pridruživanjem vrijednosti istinitosti atomarnim sudovima od kojih je sačinjen. Tako, primjerice, treći redak u tablici d) odgovara interpretaciji $i_3: \{P, Q\} \mapsto \{0, 1\}$ suda $F: P \rightarrow Q$, u kojoj je $i_3(P) = 1$, $i_3(Q) = 0$ i $i_3(P \rightarrow Q) = 0$. To znači da je u interpretaciji i_3 atomarni sud P istinit, dok su atomarni sud Q i sam sud $P \rightarrow Q$ u njoj lažni. Svakom od semantičkih tablica a) — e), gledamo li ih kao cjeline, definiramo (intuitivni) smisao odgovarajućeg logičkog veznika. Semantička tablica suda sačinjenog od n atomarnih sudova imat će 2^n redaka, od kojih svaki predstavlja jednu njegovu interpretaciju.

Usporedimo li, primjerice, semantičke tablice sudova

¹³¹ I tu uglavnom prestaje njihovo značenje za automatsku dedukciju.

$F : \neg(P \vee Q)$ i $G : \neg P \wedge \neg Q$, uočavamo da je svaki od njih istinit u onim i samo onim interpretacijama u kojima je istinit i drugi. Kažemo da su sudovi F i G (semantički) *ekvivalentni* i pišemo $F \Leftrightarrow G$.

Ova ekvivalencija jedan je od dva tzv. De Morganova¹³² poučka. Riječima se iskazuje ovako: „Negacija disjunkcije dvaju sudova ekvivalentna je konjunktiji njihovih negacija.“

Prema istinitosti s obzirom na sve svoje interpretacije sudove dijelimo u tri tipa:

DEFINICIJA 4-5:

- a. Sud F , *istinit* u *svakoj* svojoj interpretaciji, zovemo *identički istinitim sudom* ili *tautologijom*¹³³.
- b. Sud F , *istinit* bar u *jednoj* svojoj interpretaciji, zovemo *ispunljivim* ili *nekontradiktornim* sudom.
- c. Sud F , *lažan* u *svakoj* svojoj interpretaciji, zovemo *identički lažnim* sudom, *kontradiktornim* sudom ili *antitautologijom*.

Kao rodni (kanonski) zapis tautologije koristimo oznaku \top , dok oznaku \perp koristimo kao zapis antitautologije.

Iz ove definicije neposredno proistječu neke veze između definiranih pojmova. Tako je, primjerice, očigledno da je negacija identički istinitog suda identički lažan sud. Nadalje, ako neki sud nije ispunjiv, onda on očigledno nije ni identički istinit. Naravno, sud ne mora biti identički istinit da bi bio ispunjiv.

Sada možemo definirati pojam logičke posljedice za račun sudova na razini semantike.

¹³² Augustus De Morgan,...

¹³³ Čitatelj će se lako uvjeriti da su sve sheme aksioma koje smo sreli tijekom pristupa računu sudova kroz sintaksu zapravo tautologije, dakle univerzalno istinite tvrdnje. To objašnjava njihov izbor kao (shema) aksiom i čini *tajnu vezu* između sintakse i semantike računa sudova.

Prethodna definicija razvrstala je sudove u tri tipa sukladno njihovoj istinitosti u svim njihovim interpretacijama. Krajnosti predstavljaju sudovi koji su uvijek samo istiniti ili uvijek samo lažni, neovisno o kontekstu. Međutim, logičko zaključivanje u svakodnevnom životu ponajviše je kontekstno, u smislu da istinitost određenog suda u određenom kontekstu (interpretaciji) ovisi o istinitosti nekih drugih sudova u istom kontekstu. Tako je, primjerice, istinitost suda G : „Sutra je četvrtak“ ovisna o istinitosti suda F : „Danas je srijeda“. Ako je sud F istinit, tj. ako je uistinu „danas srijeda“, onda je uistinu „sutra četvrtak“, tj. i sud G je istinit. Opći kontekst ovisnosti istinitosti danog suda G o istinitosti skupa sudova u svim njegovim interpretacijama dovodi do pojma logičke posljedice za račun sudova na razini semantike, sukladno sljedećoj definiciji:

DEFINICIJA 4-6: Kažemo da je sud G logička posljedica skupa sudova $\mathcal{F} = \{F_1, F_2, \dots, F_n\}$ ako i samo ako je sud G istinit u svakoj svojoj interpretaciji u kojoj je istinit svaki od sudova F_1, F_2, \dots, F_n i pišemo $\mathcal{F} \models G$ (ili, ako je potrebno, $\{F_1, F_2, \dots, F_n\} \models G$).

Nađe li se bar jedna interpretacija suda G u kojoj su svi sudovi F_1, F_2, \dots, F_n istiniti, a sam sud G u njoj je lažan, taj sud neće biti logička posljedica skupa sudova, što pišemo kao $\mathcal{F} \not\models G$.

PRIMJER 4-8: Provjeriti je li sud $G : P \rightarrow R$ logička posljedica sudova $F_1 : P \rightarrow Q$ i $F_2 : P \rightarrow (Q \rightarrow R)$?

Da bude $\{F_1, F_2\} \models G$, tj. $\{P \rightarrow Q, P \rightarrow (Q \rightarrow R)\} \models P \rightarrow R$, dovoljno je da sud $P \rightarrow R$ bude istinit u svakoj svojoj interpretaci-

ji u kojoj su istiniti sudovi $P \rightarrow (Q \rightarrow R)$ i $P \rightarrow Q$.

	P	Q	R	$P \rightarrow Q$	$Q \rightarrow R$	$P \rightarrow (Q \rightarrow R)$	$P \rightarrow R$
i_1	0	0	0	1	1	1	1
i_2	0	0	1	1	1	1	1
i_3	0	1	0	1	0	1	1
i_4	0	1	1	1	1	1	1
i_5	1	0	0	0	1	1	0
i_6	1	0	1	0	1	1	1
i_7	1	1	0	1	0	0	0
i_8	1	1	1	1	1	1	1

Iz gornje semantičke tablice vidljivo je da su sudovi $P \rightarrow Q$ i $P \rightarrow (Q \rightarrow R)$ istodobno istiniti u interpretacijama i_1 – i_4 i i_8 te da je u svakoj od njih istinit i sud $P \rightarrow R$. Stoga je sud $P \rightarrow R$ logička posljedica sudova $P \rightarrow Q$ i $P \rightarrow (Q \rightarrow R)$.

Automatska dedukcija logičkih posljedica u okružju računa sudova

Cilj automatske dedukcije u okružju svakog logičkog računa jest utvrditi je li dana formula dotičnog računa logička posljedica polaznog skupa formula. U slučaju računa sudova, odgovor može biti „da“ ili „ne“. U slučaju računa predikata (prvog i viših redova) moguće je i „izračunati“ uvjete pod kojima je odgovor „da“, odnosno „ne“. Semantičke tablice u slučaju računa sudova načelno predstavljaju (neformalnu) metodu (proceduru) za rješavanje problema logičkog izvoda, koja je k tome odlučiva, u smislu da će odgovor na postavljeno pitanje uvijek biti „da“ (kada je uistinu $\{F_1, F_2, \dots, F_n\} \models G$), odnosno „ne“ (kada to uistinu ne bude slučaj).

Ono zbog čega metoda semantičkih tablica nije pogodna za praktične potrebe rješavanja problema logičkog izvoda jest eksponencijalan rast broja interpretacija suda F s obzirom na broj atomarnih sudova od kojih je on sačinjen. Govori se o tzv. *kombinatornoj eksploziji*. U praksi nisu nepoznati slučajevi praktičnih problema logičkog izvoda sa desecima pa i stotinama tisuća atomarnih sudova i milijardama nastupa logičkih veznika u logičkim formulama, što je za metodu semantičkih tablica, u kontekstu čak i najsvremenije postojeće tehnologije obrade informacija, vremenski gledano, neostvariva zadaća. Primjerice, u knjizi A. Karpenko: *Lukasiewicz Logics and Prime Numbers*, Luniver Press, 2006, autor navodi formulu kojom se u logici Lukasiewicza F_{n+1} prost broj karakterizira formulom, u kojoj logički veznik, tzv. *Shefferov štapić*, nastupa točno 648 042 744 959 puta.

Računalom potpomognuto rješavanje problema može biti vrlo zahtjevno i s obzirom na potrošnju memorije. Jedno računalno opovrgnuće iskaza tzv. booleovskog (ili binarnog) problema Pitagorinih trojki iz 2016. g. (je li sve prirodne brojeve moguće „obojati“ u dvije „boje“¹³⁴, tako da nijedna trojka brojeva a, b, c , za koju je $a^2+b^2=c^2$ (zadovoljava Pitagorin poučak), ne bude obojana jednom te istom „bojom“). Računalna provjera pokazala je da je hipoteza valjana za prva 7824 prirodna broja, ali ne i za njih 7825. Provjera je potrošila 200TB memorije. Više informacija čitatelj će pronaći na poveznicama poput <https://gizmodo.com/the-worlds-biggest-ever-math-proof-is-a-whopping-200tb-1779106396>.

Kao „cukor na kraju“, recimo i to da unatoč uvriježenom

¹³⁴ „boja“ može biti bilo koja oznaka.

mišljenju, računala nisu svemoguća. Naime, ne samo da postoje tzv. *masovni algoritamski nerješivi problemi*, tj. problemi parametrizirani nekim prirodnim parametrom, s beskonačno mnogo instanci, za koje ne postoje univerzalni algoritmi za njihovo rješavanje, već je cijeli „kognitivni prostor“ njima vrlo napučen. Jedan je, recimo, neizmjerljivo važan problem ispunjivosti formula računa predikata prvog reda (A. Church, 1936). I posve za kraj, recimo i to da ni među algoritamski nerješivim problemima („kao ni med cvetjem“, da se spomenemo Miroslava Krležu) „ni pravice“, što će reći da iako su *svi nerješivi*, ipak nisu *svi jednako teško nerješivi*, tj. jedni su nerješivi lakše, a drugi teže!

Vrativši se s ove male digresije, nadamo se poticajne za čitateljevu znatizeljju, zaključujemo da je nužno imati učinkovitiju metodu (ili više njih) koja će se moći puno uspješnije nositi s kombinatnom eksplozijom negoli je to kadra metoda semantičkih tablica. Cijeli jedan niz takvih metoda temelji se na tzv. *pravilu rezolucije* za račun sudova i njegovim brojnim inačicama. Da bi se osiguralo valjano okružje za definiranje i primjenu pravila rezolucije nužne su dvije stvari:

- a. Definiciju pojma logičke posljedice za račun sudova, iskazanu kroz pojam interpretacije suda, dakle jedan ne-logički (skupovni) konstrukt, nužno je vratiti u okružje računa sudova. To se čini uz pomoć dvaju poučaka karakterizacije pojma logičke posljedice za račun sudova, od kojih se jedan oslanja na pojam istine, a drugi na pojam laži.
- b. Uzme li se u obzir činjenica da su sudovi u smislu tipa strukture podataka zapravo binarna stabla, dakle nelinearna struktura podataka, bilo bi poželjno, pače nužno,

takvu strukturu sudova „linearizirati“ i tome zatim prilagoditi strukturu budućih pravila logičkog izvoda.

Linearizacija suda postiže se njegovim preoblikovanjem u pripadajući skup disjunkta (literala povezanih veznikom \vee).

Izlaganje nastavljamo poučcima o karakterizaciji pojma logičke posljedice za račun sudova.

POUČAK 4-2: Sud G logička je posljedica skupa sudova $\mathcal{F} = \{F_1, F_2, \dots, F_n\}$ ako i samo ako je sud $(F_1 \wedge F_2 \wedge \dots \wedge F_n) \rightarrow G$ tautologija.

POUČAK 4-3: sud G logička je posljedica skupa sudova $\mathcal{F} = \{F_1, F_2, \dots, F_n\}$ ako i samo ako je sud $(F_1 \wedge F_2 \wedge \dots \wedge F_n) \wedge \neg G$ kontradiktoran.

U pitanjima automatizacije logičkog izvoda za račun sudova u daljnjem ćemo se oslanjati na Poučak 4-3, koji pojam logičke posljedice iskazuje kroz pojam kontradiktornosti¹³⁵.

Metoda dokazivanja tvrdnji *svođenjem na kontradikciju* polazi od pretpostavke da poučak koji treba dokazati zapravo nije istinit. Iz te pretpostavke zatim se izvode daljnje logičke posljedice od kojih će zadnja u nizu biti u kontradikciji s nekom tvrdnjom koja je na snazi (koja je istinita) od ranije (to je najčešće tvrdnja iz pretpostavke poučka koji želimo dokazati). Jedinu moguću zaključak je da je do kontradikcije dovela pretpostavka o neistinitosti poučka koji se želi dokazati te da ta pretpostavka ne može biti istinita, iz čega se na kraju zaključuje da je poučak koji se želi dokazati uistinu istinit.

Slijedom Poučka 4-3 o karakterizaciji pojma logičke posljedice za račun sudova, početni problem, $\{F_1, F_2, \dots, F_n\} \models G$ (je li

¹³⁵ To je u skladu s narodskom intuicijom, iskazanom uzrečicom „U laži su kratke noge“.

sud G logička posljedica skupa sudova $\{F_1, F_2, \dots, F_n\}$, svodi se na problem dokaza kontradiktornosti suda $(F_1 \wedge F_2 \wedge \dots \wedge F_n) \wedge \neg G$.

Sljedeći korak ka stvaranju okružja za automatsku dedukciju logičkih posljedica u okružju računa sudova jest ranije spomenuta „linearizacija“ suda, u ovom slučaju suda $(F_1 \wedge F_2 \wedge \dots \wedge F_n) \wedge \neg G$. Ona će biti ostvarena njegovim pretvaranjem u tzv. *konjunktivnu primitivnu normalnu formu*. Za to prvo treba definirati dva posebna tipa suda: *disjunkt*, odnosno *konjunkt*.

DEFINICIJA 4-7: Disjunkt (oznaka D po potrebi s indeksima) je disjunkcija literala, tj. svaki sud oblika $D : L_1 \vee L_2 \vee \dots \vee L_n$.

PRIMJER 4-7: Sudovi $D_1 : P$ i $D_2 : \neg P \vee Q \vee R \vee \neg S$ su disjunkt.

PRIMJER 4-9: Prazni disjunkt je disjunkt koji ne sadrži niti jedan literal (oznaka $D : \phi$).

Lako je pokazati da je prazni disjunkt ekvivalentan identički lažnom ili kontradiktornom sudu, koji stoga možemo zvati i identički lažnim ili kontradiktornim disjunktom.

DEFINICIJA 4-8: Konjunkt (oznaka K po potrebi s indeksima) je konjunkcija literala, tj. svaki sud oblika: $K : L'_1 \wedge L'_2 \wedge \dots \wedge L'_m$.

PRIMJER 4-10: Sudovi $K_1 : P \wedge \neg R$ i $K_2 : R \wedge \neg S \wedge \neg T$ su konjunkt.

DEFINICIJA 4-9: Sud F je u *konjunktivnoj primitivnoj normalnoj formi*¹³⁶ ako je građen kao konjunkcija disjunkt, tj. ako ima

¹³⁶ Izraz *primitivna konjunktivna normalna forma* reduciramo na izraz *konjunktivna normalna forma*, odnosno na akronim KNF

oblik:

$$F : \underbrace{(L_{11} \vee L_{12} \vee \dots \vee L_{1k_1})}_{D_1} \wedge \underbrace{(L_{21} \vee L_{22} \vee \dots \vee L_{1k_2})}_{D_2} \wedge \dots \\ \wedge \underbrace{(L_{r1} \vee L_{r2} \vee \dots \vee L_{rk_r})}_{D_r}.$$

PRIMJER 4-II: Sud $F : (\neg P) \wedge (Q \vee \neg R \vee \neg S) \wedge (P \vee S \vee R)$ građen je kao konjunkcija disjunkta $D_1 : \neg P$, $D_2 : Q \vee \neg R \vee \neg S$ i $D_3 : P \vee S \vee R$ te je stoga u konjunktivnoj primitivnoj normalnoj formi.

DEFINICIJA 4-IO: Sud F je u disjunktivnoj primitivnoj normalnoj formi ako je građen kao disjunkcija konjunkta, tj. ako ima oblik:

$$F : \underbrace{(L_{11} \wedge L_{12} \wedge \dots \wedge L_{1k_1})}_{K_1} \vee \underbrace{(L_{21} \wedge L_{22} \wedge \dots \wedge L_{2k_2})}_{K_2} \vee \dots \\ \vee \underbrace{(L_{r1} \wedge L_{r2} \wedge \dots \wedge L_{rk_r})}_{K_r}$$

PRIMJER 4-I2: Sud $K : (\neg P \wedge Q) \vee (R \wedge \neg S) \vee (P \wedge Q \wedge R \wedge S)$ građen je kao disjunkcija konjunkta $K_1 : \neg P \wedge Q$, $K_2 : R \wedge \neg S$ i $K_3 : P \wedge Q \wedge R \wedge S$, i stoga je u disjunktivnoj primitivnoj normalnoj formi.

Definicije 4-9 i 4-10 ukazuju na činjenicu da su KNF i DNF međusobno dualne forme sudova, što će reći da jedna iz druge nastaje istodobnom zamjenom svakog nastupa veznika \wedge veznikom \vee i obratno.

PRIMJER 4-I3: Sudovi $F:(\neg P \wedge Q) \vee (R \wedge \neg S) \vee (P \wedge Q \wedge R \wedge S)$ i $G:(\neg P \vee Q) \wedge (R \vee \neg S) \wedge (P \vee Q \vee R \vee S)$ međusobno su dualni.

Svaki sud, uz pomoć ekvivalencija s narednog popisa, moguće je preoblikovati u njemu semantički ekvivalentan sud u KNF ili DNF:

1. $F \leftrightarrow G \equiv (F \rightarrow G) \wedge (G \rightarrow F)$
2. $F \rightarrow G \equiv \neg F \vee G$
3. a. $F \vee G \equiv G \vee F$ b. $F \wedge G \equiv G \wedge F$
4. a. $(F \vee G) \vee H \equiv F \vee (G \vee H)$ b. $(F \wedge G) \wedge H \equiv F \wedge (G \wedge H)$
5. a. $F \vee (G \wedge H) \equiv (F \vee G) \wedge (F \vee H)$ b. $F \wedge (G \vee H) \equiv (F \wedge G) \vee (F \wedge H)$
6. a. $F \vee \perp \equiv F$ b. $F \wedge \top \equiv F$
7. a. $F \vee \top \equiv \top$ b. $F \wedge \perp \equiv \perp$
8. a. $F \vee \neg F \equiv \top$ b. $F \wedge \neg F \equiv \perp$
9. $\neg(\neg F) \equiv F$
10. a. $\neg(F \vee G) \equiv \neg F \wedge \neg G$ b. $\neg(F \wedge G) \equiv \neg F \vee \neg G$

PRIMJER 4-I4: Sud $(P \wedge (Q \rightarrow R)) \rightarrow S$ preoblikovati¹³⁷ u konjunktivnu normalnu formu:

$$\begin{aligned}
& (P \wedge (Q \rightarrow R)) \rightarrow S \equiv \\
& \stackrel{2)}{\equiv} (P \wedge (\neg Q \vee R)) \rightarrow S \equiv \\
& \stackrel{2)}{\equiv} \neg((P \wedge (\neg Q \vee R)) \vee S) \equiv \\
& \stackrel{10)b)}{\equiv} (\neg P \vee \neg(\neg Q \vee R)) \vee S \equiv \\
& \stackrel{10)a)}{\equiv} (\neg P \vee (\neg(\neg Q) \wedge \neg R)) \vee S \equiv
\end{aligned}$$

¹³⁷ Naravno, sustavi automatske dedukcije sve nužne pretvorbe rade sami.

$$\begin{aligned}
& \stackrel{9}{\equiv} (\neg P \vee (Q \wedge \neg R)) \vee S \equiv \\
& \stackrel{5)a)}{\equiv} ((\neg P \vee Q) \wedge (\neg P \vee \neg R)) \vee S \equiv \\
& \stackrel{3)a)}{\equiv} S \vee ((\neg P \vee Q) \wedge (\neg P \vee \neg R)) \equiv \\
& \stackrel{5)a)}{\equiv} (S \vee (\neg P \vee Q)) \wedge (S \vee (\neg P \vee \neg R)) \equiv \\
& \stackrel{4)a)}{\equiv} (S \vee \neg P \vee Q) \wedge (S \vee \neg P \vee \neg R)
\end{aligned}$$

Iz konjunktivne normalne forme suda F u obliku:

$$F: D_1 \wedge D_2 \wedge \dots \wedge D_n,$$

izdvajanjem disjunktata u zaseban skup, nastaje skup disjunktata \mathcal{D} . Skup disjunktata $\mathcal{D} = \{D_1, D_2, \dots, D_n\}$ zovemo skupom reprezentanata suda F .

Sukladno semantičkoj tablici veznika \wedge , da sud

$$F: D_1 \wedge D_2 \wedge \dots \wedge D_n$$

bude kontradiktoran, tj. da bude lažan u svakoj svojoj interpretaciji, nužno je i dovoljno da u svakoj njegovoj interpretaciji bude lažan bar jedan od disjunktata D_1, D_2, \dots, D_n . Tim zahtjevom prirodno definiramo i kontradiktornost pripadajućeg skupa disjunktata $\mathcal{D} = \{D_1, D_2, \dots, D_n\}$.

DEFINICIJA 4-II: Kažemo da je skup disjunktata

$$\mathcal{D} = \{D_1, D_2, \dots, D_n\}$$

kontradiktoran ako i samo ako je u svakoj njegovoj interpretaciji lažan bar jedan od disjunktata D_1, D_2, \dots, D_n .

Da je skup disjunktata $\mathcal{D} = \{D_1, D_2, \dots, D_n\}$ kontradiktoran, na

drugi se način može izreći sljedećim poučkom:

POUČAK 4-4: Ako je $\mathcal{D}=\{D_1, D_2, \dots, D_n\} \models \perp$, onda je skup \mathcal{D} kontradiktoran.

Poučak je neposredna posljedica drugog poučka o karakterizaciji pojma logičke posljedice za račun sudova.

Sada smo u mogućnosti oblikovati opći okvir za automatizaciju logičkog izvoda na razini semantike za račun sudova:

POLAZNI PROBLEM:

Utvrđiti je li sud G logička posljedica skupa sudova
 $\mathcal{F}=\{F_1, F_2, \dots, F_n\}$, tj. je li $\{F_1, F_2, \dots, F_n\} \models G$.

METODA:

- I. Sukladno Poučku 4-3, bit će $\{F_1, F_2, \dots, F_n\} \models G$ bude li sud $F : (F_1 \wedge F_2 \wedge \dots \wedge F_n) \wedge \neg G$ kontradiktoran.
- II. Sud F preoblikujemo u njemu ekvivalentan sud $D_1 \wedge D_2 \wedge \dots \wedge D_m$ u primitivnoj konjunktivnoj normalnoj formi i zatim u skup disjunkta $\mathcal{D}=\{D_1, D_2, \dots, D_m\}$.
- III. Sukladno Poučku 4-4: skup disjunkta $\mathcal{D}=\{D_1, D_2, \dots, D_m\}$ bit će kontradiktoran bude li $\mathcal{D}=\{D_1, D_2, \dots, D_m\} \models \perp$.

IV. Iz skupa $\mathcal{D}=\{D_1, D_2, \dots, D_m\}$ izvodimo logičke posljedice, sve dok jedna među njima ne bude identički lažan ili kontradiktoran disjunkt \perp , što prema prethodnoj točki predstavlja potvrdu kotradiktornosti skupa \mathcal{D} , što opet, prema točki II., sud $D: D_1 \wedge D_2 \wedge \dots \wedge D_m$ čini kontradiktornim te stoga takvim čini i sud $F: (F_1 \wedge F_2 \wedge \dots \wedge F_n) \wedge \neg G$, iz čega, na kraju, slijedom Poučka 4-2, slijedi da je sud G logička posljedica skupa sudova $\mathcal{F}=\{F_1, F_2, \dots, F_n\}$.

Ostaje pronaći valjano pravilo logičkog izvoda, koje će djelovati na disjunkte, kao valjane logičke posljedice davati nove disjunkte i uzastopno se primjenjivati na disjunkte iz polaznog skupa disjunkta \mathcal{D} te iz njih izvedene disjunkte, u potrazi za identički lažnim disjunktom kao potvrdom kontradiktornosti polaznog skupa disjunta \mathcal{D} te u krajnjoj instanci potvrdom da je neki sud G logička posljedica skupa sudova $\mathcal{F}=\{F_1, F_2, \dots, F_n\}$.

Takvo pravilo postoji, zove se *pravilo rezolucije*, a pored do sada navedenih svojstava iskazuje i svojstvo potpunosti, u smislu da njegova sustavna primjena na kontradiktorne skupove disjunkta u konačnici rezultira potvrdom njihove kontradiktornosti, naravno, kako je već rečeno, generiranjem identički lažnog ili kontradiktornog disjunkta.

DEFINICIJA 4-I2: Neka su $D_1 : L \vee D_1$ i $D_2 : \neg L \vee D_2'$ dva disjunkta¹³⁸ i L literal. Rezolventom disjunkta D_1 i D_2 po literalu L zovemo disjunkt $D_3 : res_L(D_1, D_2) : D_1' \vee D_2'$.

PRIMJER 4-I5: Neka je $D_1 : \neg P \vee \neg Q \vee T$. i $D_2 : \neg P \vee \neg Q \vee T$. Tada je $res_P(D_1, D_2) : \neg Q \vee \neg R \vee T$.

PRIMJER 4-I6: Neka je:

$$D_1 : \neg P \vee R \vee \neg T \vee S \text{ i } D_2 : P \vee \neg Q \vee T \vee S \vee U.$$

Tada je pomoću disjunkta D_1 i D_2 moguće izgraditi dvije rezolvente, jednu po literalu P , a drugu po literalu T :

$$D_3 : res_P(D_1, D_2) : \neg Q \vee R \vee T \vee \neg T \vee S, \text{ i}$$

$$D_4 : res_T(D_1, D_2) : P \vee \neg P \vee \neg Q \vee R \vee S.$$

Očigledno je da su obje te rezolvente tautologije, što je slučaj svaki put kada dva disjunkta od kojih se rezolvente grade sadrže više od jednog para suprotnih literala (ovdje su to P i $\neg P$, odnosno T i $\neg T$). Potvrdi kontradiktornosti kontradiktornih skupova disjunkta tautologije ni odmažu (kontradiktoran skup disjunkta takvim će ostati i ako se iz njega uklone disjunkt-tautologije), ni pomažu (disjunkt-tautologija ne može biti lažan ni u jednoj svojoj interpretaciji).

Od svakog pravila logičkog izvoda očekuje se da u primjeni daje valjane logičke posljedice. To, naravno, vrijedi i za pravilo rezolucije za račun sudova, što će reći da je rezolventa dvaju

¹³⁸ Sukladno strukturi disjunkta to znači da su D_1' i D_2' također disjunkt.

disjunkta njihova logička posljedica. Poučak ne dokazujemo.

Neka je $D_1: P$ i $D_2: \neg P$. Tada je $res_p(D_1, D_2): \phi$, gdje je ϕ prazan skup, tj. *prazna rezolventa*. Zamjena sudova $D_1: P$ i $D_2: \neg P$ njima ekvivalentnim sudovima $D'_1: P \vee \perp$ i $D'_2: \neg P \vee \perp$ (ekvivalencija 6) a) u Tablici 2.4.I), daje: $\phi: res_p(D_1, D_2) \equiv res_p(D'_1, D'_2): \perp$, što znači da je prazna rezolventa zapravo ekvivalentna identički lažnom ili kontradiktornom disjunktumu.

PRIMJER 4-I7: Uz pomoć pravila rezolucije dokazati kontradiktornost skupa disjunkta

$$\mathcal{D} = \{\underbrace{P \vee Q}_{D_1}, \underbrace{\neg P \vee Q}_{D_2}, \underbrace{P \vee \neg Q}_{D_3}, \underbrace{\neg P \vee \neg Q}_{D_4}\}.$$

Skup disjunkta $\mathcal{D} = \{\underbrace{P \vee Q}_{D_1}, \underbrace{\neg P \vee Q}_{D_2}, \underbrace{P \vee \neg Q}_{D_3}, \underbrace{\neg P \vee \neg Q}_{D_4}\}$ kontradiktoran je jer je disjunkt D_1 lažan u interpretaciji $i_1 = \{\neg P, \neg Q\}$, disjunkt D_2 lažan u interpretaciji $i_2 = \{P, \neg Q\}$, disjunkt D_3 lažan u interpretaciji $i_3 = \{\neg P, Q\}$ i disjunkt D_4 lažan u interpretaciji $D_4: P \vee Q$. Uvjerimo se u to još jednom uz pomoć pravila rezolucije:

$$D_1: P \vee Q$$

$$D_2: \neg P \vee Q$$

$$D_3: P \vee \neg Q$$

$$D_4: \neg P \vee \neg Q$$

$$D_5: res_p(D_1, D_2): Q$$

$$D_6: res_p(D_3, D_4): \neg Q$$

$$D_7: res_p(D_5, D_6): \perp$$

Disjunkt $D_7 : \perp$ potvrda je kontradiktornosti skupa disjunkta \mathcal{D} . Disjunki $D_5 - D_7$ oblikovani su vizualnim uvidom u strukturu disjunkta $D_1 - D_4$. Računala, kao ni za njih razvijene aplikacije, taj vizualni uvid (još za neko vrijeme) nemaju. Stoga je za potrebe utvrđivanja kontradiktornosti polaznog skupa disjunkta rezolvente nužno generirati sustavno. O tome brinu pozadinski deduktivni mehanizmi sustava automatske logičke dedukcije.

Izvorno pravilo rezolucije do danas je modificirano na mnoštvo načina, sve u cilju povećanja učinkovitosti logičkog izvoda. Današnji sustavi automatske dedukcije za račun sudova, tzv. *SAT*¹³⁹-*solveri*, s lakoćom rješavaju brojne probleme industrijske razine, s desecima tisuća disjunkta.

Literatura ne vrvi ručno rješanim (uz pomoć pravila rezolucije) složenijim primjerima problema modeliranih u računu sudova. Nešto ih se može naći u (Čubrilo, 1989). Da bismo ipak ilustrirali složenost samog modeliranja problema u računu sudova, izložiti ćemo ga na primjeru tzv. *samoreferentnih kvizova*.

Pretpostavimo da polažemo test sa zaokruživanjem odgovora, s određenim brojem pitanja i (najčešće) jednakim brojem ponuđenih odgovora na svako od njih. Za test se nismo baš najbolje pripremili, ali smo doznali neke „vanjske“ podatke o njemu iz kojih bi se logičkom dedukcijom mogli utvrditi točni odgovori na sva pitanja. Poznati SAT-solver nam je nadohvat ruke. Ostaje samo valjano formulirati problem. Evo primjera!

¹³⁹ SATisfiability – ispunjivost (sudova)

PRIMJER 4-18: Samoreferentni kviz

1. Što je odgovor na drugo pitanje?

- A. A
- B. B
- C. C
- D. D

2. Koliko je točnih odgovora B?

- A. 0
- B. 1
- C. 2
- D. 3

3. Postoji li pitanje s točnim odgovorom A?

- A. Ne
- B. Da, 1
- C. Da, 2
- D. Da, sva 3

Ovaj kviz lako se može riješiti i „napamet“. Rješenje je 1.A, 2.A, 3.C. Evo kako:

Pretpostavimo da je 1.A točan odgovor.

— Onda su odgovori 1.B-1.D svi lažni.

— Zatim, točan je 2.A, tj. B je dao 0 točnih odgovora, pa su lažni i odgovori 1.B-3.B, kao i 2.C i 3.C.

— Odgovor 3.A ne može biti točan, jer ako je točan, onda je odmah i netočan, jer ga samo pitanje #3 demantira, pa je 3.A netočan odgovor.

— To znači da točnih odgovora A ima točno dva, pa je 3.C točan odgovor, a 3.D lažan.

— Pod pretpostavkom 1.A, svi odgovori su provjereni i 1.A, 2.A, 3.C jest jedno moguće (konzistentno) rješenje. Kako su samoreferentni kvizovi građeni tako da imaju samo jedno rješenje, onda je to i jedino rješenje.

Da rješenje nismo „pogodili“ odmah, na isti način bismo ispitali i ostala moguća rješenja (i eliminirali ih).

1. U procesu modeliranja kviza prvo treba uvesti odgovarajuće varijable koje će spojiti pitanja i odgovore:
 - A_1, A_2, A_3, A_4 — prvi odgovor na prvo, drugo, treće i četvrto pitanje
 - B_1, B_2, B_3, B_4 — drugi odgovor na prvo, drugo, treće i četvrto pitanje
 - C_1, C_2, C_3, C_4 — treći odgovor na prvo, drugo, treće i četvrto pitanje

2. Svako pitanje ima bar jedan točan odgovor:
 - $A_i \vee B_i \vee C_i \vee D_i; i=1-4$ (ukupno četiri disjunktka)

3. Svako pitanje ima samo jedan točan odgovor:
 - $(A_i \wedge \neg B_i \wedge \neg C_i \wedge \neg D_i) \vee (\neg A_i \wedge B_i \wedge \neg C_i \wedge \neg D_i) \vee$
 $\vee (\neg A_i \wedge \neg B_i \wedge C_i \wedge \neg D_i) \vee (\neg A_i \wedge \neg B_i \wedge \neg C_i \wedge D_i); i=1-4$
 (ukupno šesnaest konjunkta koje treba pretvoriti u disjunkte, njih ukupno 256)

4. Semantičke veze između odgovora (ni izdaleka sve!¹⁴⁰)
 - I. Prvi odgovor na prvo pitanje je točan, tj. A_1 . Onda je broj točnih odgovora na pitanje 2 nula, pa su odgovori $B_i; i=1-2$, lažni (svaki kaže da je taj broj jednak 1), tj. $A_1 \rightarrow (\neg B_1 \wedge \neg B_2)$; ukupno 4 disjunktka

¹⁴⁰ Ima ih $4^3=64$!

- II. Drugi odgovor na prvo pitanje je točan, tj. B_1 . Onda je odgovor B_2 točan, odgovori A_1, C_1 i D_1 , kao i A_2, C_2 i D_2 netočni, tj. $B_2 \rightarrow (\neg A_i \wedge \neg C_i \wedge \neg D_i)$; $i=1-2$; ukupno 6 disjunkta
- III. Četvrti odgovor na prvo pitanje je točan, tj. D_1 . Onda je odgovor D_2 točan, odgovori A_1, B_1 i C_1 , kao i A_2, B_2 i C_2 netočni, tj. $D_2 \rightarrow (\neg A_i \wedge \neg B_i \wedge \neg C_i)$; $i=1-2$; ukupno 6 disjunkta. Nadalje, D_2 kaže da su sva tri odgovora pod B točna, što daje $D_2 \rightarrow (B_1 \wedge B_2 \wedge B_3)$; jedan disjunkt
- •
•

Čitatelj je već zasigurno zaključio da je ipak bolje spremiti predmetna znanja testa, jer je to puno lakše i svrsishodnije. Autor također.

Zagonetke poput gornje dobre su za vježbanje „malih sivih stanica“, kako bi rekao slavni detektiv Hercule Poirot, koristeći za to logiku našu svagdanju. U radu (Bubalo i Čubrilo, 2005), u jeziku Mozart/OZ, jednom od ranih programskih jezika koji je spojio logičko i klasično linearno programiranje¹⁴¹, implementiran je sustav za generiranje samoreferentnih kvizova. Jedan od tako generiranih kvizova, naveden kao srednje težak, nalazi se na poveznici <https://www.brainzilla.com/logic/self-referential-quiz/srq-2/>.

¹⁴¹ U engleskoj terminologiji *constraint logic programming languages*.

O računu predikata prvog reda

Račun predikata prvog reda temeljni je logički račun na kojem počivaju današnji sustavi automatske dedukcije, uključujući kako specifične alate, tako i logičke programske jezike i njihova proširenja. I u njegovu slučaju pristup automatizaciji logičke dedukcije ide kroz semantiku. U idejnom smislu pravilo rezolucije za račun predikata (RP) istovjetno je onome računa sudova, ali s puno dodatnih „tehničkih zahvata“, da nabrojimo samo neke.

1. Gramatika jezika RP bitno je obuhvatnija od gramatike jezika RS. Abeceda jezika RP sadrži prebrojive skupove konstanti, varijabli, funkcijskih i predikatnih znakova svih konačnih kratnosti, skup logičkih veznika kao i RS te skup kvantifikatora, „za svaki“ i „postoji“.

2. Gradnji formula RP prethodi gradnja tzv. *terma*, objekata građenih od konstanti, varijabli i funkcijskih znakova.

3. Na terme djeluju predikatni znakovi i tako nastaju atomarne formule, koje su analog atomarnih sudova RS.

4. Formule RP u punom značenju analog su sudova RS a građene su uz pomoć atomarnih formula, logičkih veznika i kvantifikatora te su stoga sintaktički puno složenije.

5. Aksiomatika RP koja posredno dolazi do izražaja u pripremi skupa formula za automatsku dedukciju, bitno je bogatija.

6. Domena interpretacije formule RP može biti bilo kakav skup, za razliku od RS, gdje ju je činio skup {„istina“, „laž“}.

7. Pretvaranje formule u konjunktivnu normalnu formu te zatim skup disjunkta za potrebe primjene pravila rezolucije

daleko je složenije. Problem domene interpretacije u slučaju kontradiktornih skupova disjunkta rješavaju tzv. *Herbrandove interpretacije*, koje su zapravo sintaktičkog karaktera.

8. Gradnja rezolventi između disjunkata uključuje pret-hodnu *unifikaciju*, tj. ujednačavanje na sintaktički istovjetnu formu, koje u pozadini apsorbira (čini ga konzistentnim) tzv. *Herbrandov model*.

Olakotna okolnost je da i u slučaju **RP** za skupove formula bez tzv. *slobodnih varijabli* i dalje vrijede poučci o karakterizaciji pojma logičke posljedice.

Koliko je autoru poznato, jedina knjiga na hrvatskom jeziku u kojoj se **RP** izlaže u kontekstu automatske dedukcije je (Čubrilo, 1989).

Logički programi građeni su kao skupovi Hornovih (ili hornovskih) klauzula, tj. kao disjunkta, građeni od atomarnih formula i njihovih negacija, ali sa najviše jednim negativnim literalom.

O logičkim programskim jezicima, posebice Prologu i njegovim primjenama, napisano je mnoštvo knjiga. Jedna od autoru najdražih i ujedno jedna od prvih, jest knjiga (Bratko, 1986), sada već u četvrtom izdanju. Ona vrlo pažljivo i prijateljski izlaže osnove samog jezika, njegovu sintaksu i semantiku te niz logičkih programskih konstrukata rastuće složenosti, uključujući i primjene u području umjetne inteligencije.

Kao jednu od brojnih primjena logičkih programskih jezika u službi humanistike spomenimo izvedbu sučelja za Prolog (a time i radnog okružja) poznatog digitalnog jezičnog resursa za engleski jezik, WordNet. Već niz godina postoji i inačica toga resursa za

hrvatski jezik (Raffaelli i sur., 2008).

Nakon cijele priče o logičkom programiranju nije red da čitatelja ostavimo bez bar jednog (ilustrativnijeg i zabavnijeg) primjera njegove primjene. Tu ćemo opet unovačiti svima poznatu logičku zagonetku o vuku, kozi i kupusu, modelirati je u Prologu i prikazati Prologom generirana rješenja.

Čitatelj se već uvjerio da su logičke zagonetke u tom kontekstu vrlo zahvalno problemsko područje jer su u sadržajnom (semantičkom) smislu vrlo zgusnute. Modeliranje i rješavanje „većih“ problema u kontekstu ove knjige nije primjereno.

Izlaganje temeljimo prema izvorima na poveznicama https://cseweb.ucsd.edu/classes/fa09/cse130/misc/prolog/goat_etc.html i <https://danielschlegel.org/wp/teaching/prolog-farmer-goat-wolf-cabbage/>, uz nešto autorovih intervencija i komentara. Izloženi model problema nije jedini moguć, ali je vrlo elegantan.

PRIMJER 4-19: (problem vuka, koze i kupusa)

Farmer čamcem s jedne obale rijeke na drugu mora prevesti vuka, kozu i kupus. Čamac ima mjesta za dvije „osobe“. Ostanu li vuk i koza sami na jednoj obali rijeke, vuk će posjesti kozu, dok će u slučaju da to budu koza i kupus, koza pojesti kupus. Problem je utvrditi „vozni red“ čamca tako da cijelo „društvo“ sretno i sigurno prijeđe s jedne obale rijeke na drugu.

Kako je već ranije napomenuto, pola rješenja problema predstavlja njegovo valjano modeliranje.

Lijevu, odnosno desnu obalu rijeke označimo s *l*, odnosno *d*. Kako je Prolog izvrstan u radu s listama, onda se stanje „druženja“ u svakom trenutku može opisati listom s četiri elementa, kodirana

znakovima *d* i *l*, pod pretpostavkom da prvi element liste uvijek znači poziciju farmera, drugi vuka, treći koze i četvrti kupusa. Početnu poziciju problema opisuje lista $[l,l,l,l]$, a završnu lista $[d,d,d,d]$. Tako lista $[l,l,d,d]$ znači da su farmer i vuk na lijevoj obali rijeke, a koza i kupus na desnoj, što nije dopustivo jer će koza tada pojesti kupus.

U svakoj vožnji čamcem farmer može voziti samo vuka, samo kozu, samo kupus ili nikoga, pa se one redom mogu prikazati kao *vuk, koza, kupus, nitko* (farmer je stalni putnik pa ga ne treba posebno kodirati).

Svaka vožnja promijenit će listu pozicija na lijevoj i desnoj obali rijeke. To se može opisati predikatom

voznja(Stanje,Putnik,NovoStanje)

Prevozi li farmer s lijeve obale na desnu, primjerice, kupus, onda će jedna instanca predikata *voznja* izgledati ovako:

voznja([l,d,l,l],kupus,[d,d,l,d]).

U procesu modeliranja problema poželjan je dobar odnos „potrošnje“ činjenica i uvođenja apstraktnih pravila. Primjerice, predikat

*voznja([l,l,Koza,Kupus],vuk,[d,d,Koza,Kupus]).*¹⁴²

gdje su *Koza* i *Kupus* varijable¹⁴³ opisuje stanje nakon što je farmer s lijeve strane rijeke na desnu prevezao vuka. Koza i kupus pritom ostaju gdje su i bili. Svaki par njihovih pozicija dao bi dvije nove činjenice, pa bi ih bilo ukupno četiri. Gornje pravilo pokriva ih sve. Također, situacija je simetrična i s obzirom na zamjenu lijeve obale rijeke desnom i obratno, tj.

voznja([l,l,Koza,Kupus],vuk,[d,d,Koza,Kupus]).

¹⁴² Točka na kraju pravilo je sintakse Prologa.

¹⁴³ Varijable u Prologu počinju velikim slovom.

Uvođenjem novog predikata *suprotnaObala*, sa činjenicama:

suprotnaObala(l,d).

suprotnaObala(d,l).

gornja dva predikata mogu se ujediniti: Netom opisana simetrija sada se može izreći pravilom:

voznja([X,X,Koza,Kupus],vuk,[Y,Y,Koza,Kupus]) :- *suprotnaObala*(X,Y).

Znak :- čita se *ako je*.

Sve do sada rečeno o problemu sažimlje se u sljedeći ulomak kôda u Prologu:

suprotnaObala(l,d).

suprotnaObala(d,l).

voznja([X,X,Koza,Kupus],vuk,[Y,Y,Koza,Kupus]) :- *suprotnaObala*(X,Y).

voznja([X,Vuk,X,Kupus],koza,[Y,vuk,Y,Kupus]) :- *suprotnaObala*(X,Y).

voznja([X,Vuk,Koza,X],kupus,[Y,Vuk,Koza,Y]) :- *suprotnaObala*(X,Y).

voznja([X,Vuk,Koza,Kupus],nitko,[Y,Vuk,Koza,Kupus]) :- *suprotnaObala*(X,Y).

Sljedeće na redu jest osigurati sigurnost koze i kupusa. Svako od njih bi će sigurno budu li farmer i koza zajedno na istoj obali rijeke, odnosno budu li to vuk i kupus. To osigurava predikat u *SigurnomDruštvu* sa sljedećom semantikom:

uSigurnomDruštvu([X,_X,_]). % Farmer i koza su na istoj obali rijeke.¹⁴⁴

uSigurnomDruštvu([X,X,_X]). % Farmer, vuk i kupus su na istoj obali rijeke.

Ostaje opisati što čini rješenje problema. Definiramo istoimeno pravilo:

rjesenje([d,d,d,d],[_]). % Cijelo "društvo" prešlo je s lijeve obale rijeke na desnu i sve
% su vožnje obavljene.


¹⁴⁴ Vuk i kupus mogu biti bilo gdje.

rjesenje(Stanje,[prvaVoznja|DrugeVoznje]) :- voznja(Stanje, prvaVoznja, NovoStanje),
 uSigurnomDrustvu(NovoStanje),
 rjesenje(NovoStanje, DrugeVoznje).

Time su sam problem i njegovo rješenje opisani *načelno*. *Stvarno rješenje* čini niz promjena stanja, od početnog [l,l,l], do završnog, [d,d,d,d]. Zarez označava veznik „i“. Prolog sada možemo *upitati* za rješenje.

?- rjesenje([l,l,l,l],X).

Na sljedećim slikama (prvo rješenje) je gornji Prolog-program, realiziran u inačici SWI-Prologa namijenjenoj radu u okruženju Weba, SWISH.



SLIKA 4-36: Rješenje problema u okruženju SWISH.

```
1 suprotnaObala(1,d).
2 suprotnaObala(d,1).
3
4 voznja([X,X,Koza,Kupus],vuk,[Y,Y,Koza,Kupus]) :- suprotnaObala(X,Y).
5 voznja([X,Vuk,X,Kupus],koza,[Y,Vuk,Y,Kupus]) :- suprotnaObala(X,Y).
6 voznja([X,Vuk,Koza,X],kupus,[Y,Vuk,Koza,Y]) :- suprotnaObala(X,Y).
7 voznja([X,Vuk,Koza,Kupus],nitko,[Y,Vuk,Koza,Kupus]) :- suprotnaObala(X,Y).
8
9 uSigurnomDrustvu([X,_,X,_]).
10 uSigurnomDrustvu([X,X,_,X]).
11
12 rjesenje([d,d,d,d],[ ]).
13 rjesenje(Stanje,[PrvaVoznja|DrugeVoznje]) :- voznja(Stanje,PrvaVoznja,NovoStanje),
14                                             uSigurnomDrustvu(NovoStanje),
15                                             rjesenje(NovoStanje,DrugeVoznje).
16
17
```

SLIKA 4-37: Opis problema u okruženju SWISH.

Predikat `length` ugrađen je u sam jezik i ograničava broj iteracija predikata `rjesenje` na minimalan broj zapisa.

Epigrafi u tekstovima dolaze odmah ispod naslova knjige, članka, poglavlja u knjizi,..., a ovdje izlažemo dva¹⁴⁵, ne zbog njih samih, iako su vrijedni i sami po sebi, već da ilustriramo pretakanje teksta iz prirodnog u formalni jezik, ovaj put račun predikata (s jednakošću kao izdvojenim predikatom). Da smo baš htjeli, ovom poglavlju bio bi primjeren sljedeći:

Ne postoje prečaci do mjesta vrijednih da se do njih dođe.

(Beverly Sills)

¹⁴⁵ U osnovi prema (Groza, 2021), uz „prepjev“ i nešto korekcija.

EPIGRAF 4-1:

Postoje samo dva načina kako netko živi svoj život. Jedan je da ništa u životu ne smatra čudom. Drugi je da čudom u životu smatra baš sve.

(Albert Einstein)

$$\begin{aligned} & \exists x \exists y (\neg(x = y) \wedge (\forall z \text{ kakoŽivi}(z) \leftrightarrow (z = x \vee z = y))) \wedge \\ & \wedge (\text{kakoŽivi}(x) \rightarrow \neg(\exists u \text{ čudo}(u))) \wedge \\ & \wedge (\text{kakoŽivi}(y) \rightarrow (\forall u \text{ čudo}(u))) \end{aligned}$$

EPIGRAF 4-2:

Čovjek s čekićem u ruci svaki problem vidi kao čavao. Čekić našeg doba je algoritam.

(William Poundstone¹⁴⁶)

$$\begin{aligned} & \forall x \forall y (\text{čovjek}(x) \wedge \text{ima}(x, \check{c}) \wedge \text{čekić}(\check{c}) \wedge \text{problem}(y)) \rightarrow \\ & \rightarrow \text{vidi}(x, y, \text{čavao}). \\ & \text{veliki}(\text{čekić}, \text{našeDoba}) = \text{algoritam}. \end{aligned}$$

U kontekstu umjetne inteligencije, kao svojevrsan „događaj dana“ pojavilo se više sustava tzv. *opće umjetne inteligencije* (engl. *general artificial intelligence*) među kojima je trenutačno najpopularniji već spominjani ChatGPT. Zanimalo nas je kako se on nosi s rješavanjem logičkih problema na nekoliko primjera logičkih zagonetki.

U tome kontekstu sa sustavom je provedeno više „razgovora“, u kojima je sustavu predlagano da riješi predočene mu logičke zagonetke ili da provjeri autorova rješenja. Idemo redom:

¹⁴⁶ Manje poznat, ali plodan i izvrstan autor u području teorije igara, teorije informacija, teorije složenosti algoritama,... Vidjeti, primjerice, (Poundstone, 2011; 2013; 2016).

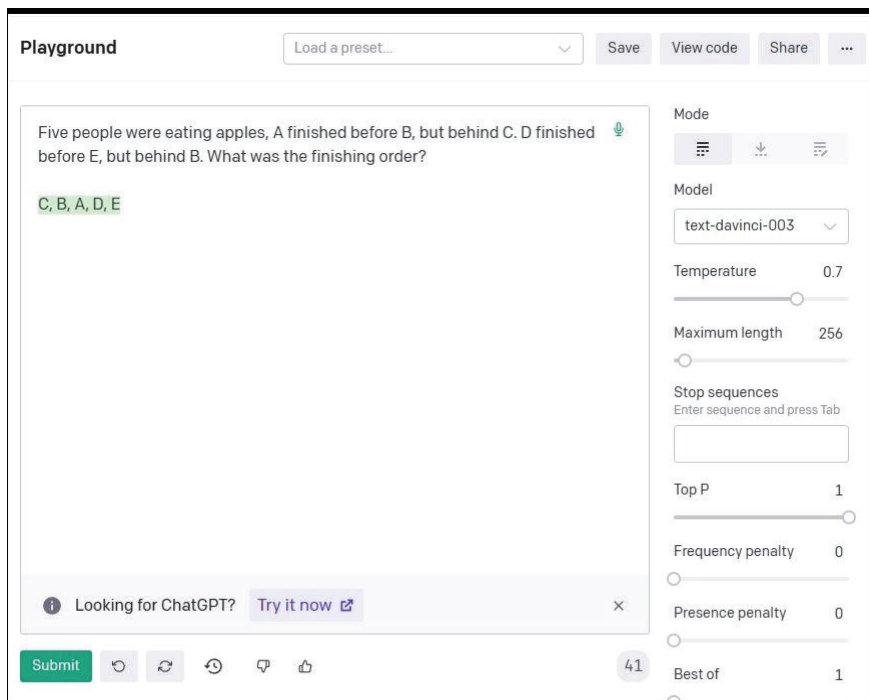
2. Logic Puzzle: Five people were eating [apples](#). A finished before B, but behind C. D finished before E, but behind B. What was the finishing order?

Answer: CABDE. Putting the first three in order, A finished in front of B but behind C, so CAB. Then, we know D finished before B, so CABD. We know E finished after D, so CABDE.

ZAGONETKA 4-I:

Izvor: <https://parade.com/970343/parade/logic-puzzles/>

Dakle, osobe A, B, C i D treba posložiti slijedom toga kako je koja od njih pojela jabuku. Pogledajmo kako je zagonetku riješio sustav ChatGPT.



SLIKA 4-38: Kako je ChatGPT riješio zagonetku.

Rješenje CBADE koje je predložio ChatGPT nažalost je netočno, čak i uz korištenje najjače izvedbe sustava (text-davinci-003)! Točno rješenje je **CABDE**.

Lako ga je dobiti, uspostavljajući krajnje jednostavan sustav nejednakosti koje problem opisuju. Ovdje $X \leq Y$, znači X je pojeo jabuku (neposredno) prije Y-a.

(1) $A \leq B$

(2) $C \leq A$

(3) $D \leq E$

(4) $B \leq D$

Iz (1) i (4) izlazi $A \leq B \leq D$, iz (3) i posljednje nejednakosti slijedi $A \leq B \leq D \leq E$, a iz nje i (2) konačno slijedi $C \leq A \leq B \leq D \leq E$.

Istini za volju, *radna temperatura* (stavka *Temperature* parametara modela) postavljena je na vrijednost 70, što uključuje značajnu mjeru slučajnosti u davanju odgovora na upite. Nije poznato točno koju (ako ikoju, izgledno je nikoju!) logiku sustav koristi za rješavanje logičkih zagonetki, ali ako da, onda predmnijevamo da bi to mogla biti neka inačica Bayesove vjerojatnosne logike. Kada je radna temperatura postavljena na vrijednost 0, sustav je javio da za potrebe odgovora na upit treba dodatne podatke, iako ni izdaleka nije jasno koji bi to podaci bili.

Druga zagonetka, s iste poveznice, zagonetka je *à la* Raymond Smullyan:

9. Logic Puzzle: There are three people (Alex, Ben and Cody), one of whom is a knight, one a knave, and one a spy. The knight always tells the truth, the knave always lies, and the spy can either lie or tell the truth. Alex says: "Cody is a knave." Ben says: "Alex is a knight." Cody says: "I am the spy." Who is the knight, who the knave, and who the spy?

Answer: We know Ben isn't telling the truth because if he was, there would be two knights; so Ben could be either the knave or the spy. Cody also can't be the knight, because then his statement would be a lie. So that must mean Alex is the knight. Ben, therefore, must be the spy, since the spy sometimes tells the truth; leaving Cody as the knave.

ZAGONETKA 4-2: IZVOR: <https://parade.com/970343/parade/logic-puzzles/>

There are three people (Alex, Ben and Cody), one of whom is a knight, one a knave, and one a spy. The knight always tells the truth, the knave always lies, and the spy can either lie or tell the truth. Alex says: "Cody is a knave." Ben says: "Alex is a knight." Cody says: "I am the spy." Who is the knight, who the knave, and who the spy? [Could you explain your answer?](#)

Alex is the knight, Ben is the knave, and Cody is the spy.

Alex is the knight because he correctly identified Cody as the knave. Ben is the knave because he incorrectly identified Alex as the knight. Cody is the spy because he correctly identified himself as the spy.

Looking for ChatGPT? [Try it now](#)

Submit



171

SLIKA 4-39: ChatGPT-ovo rješenje logičke zagonetka á la R. Smullyan.

I ovo rješenje je netočno. Točno rješenje iskazano je ispod formulacije zagonetke.

U domaćoj terminologiji neka *knight* bude *istinoljubac*, *knave* neka bude *lažac* i *spy* neka bude *smutljivac*. Dakle, istinoljubac uvi-

jek govori istinu, lažac uvijek laže, a smutljivac govori istinu, odnosno laže, po potrebi. Već znamo, valjano rješenje ove logičke zagonetke je:

- (A) Alex je istinoljubac
- (B) Ben je smutljivac
- (C) Cody je lažac

Uvjeti zagonetke kažu:

- (1) Alex: „Cody je lažac“
- (2) Ben: „Alex je istinoljubac“
- (3) Cody: „Ja sam smutljivac“

Prema ChatGPT-u, Ben je lažac, što uz (2) daje da Alex nije istinoljubac, što se protivi točki (A) odgovora ChatGPT-a. Upitan za objašnjenje svoga odgovora, ChatGPT kaže:

Alex is the knight because he correctly identified as the knave.
Ben is the knave because he incorrectly identified Alex as the knight. Cody is the spy because he correctly identified himself as the spy.

Prve dvije rečenice objašnjenja očigledno su u suprotnosti. Stjecajem okolnosti, istu zagonetku autor je ChatGPT-u prosljedio dva dana kasnije. Odgovor na upit ovaj put je bio puno opširniji (čini se kao da je sustav u međuvremenu razmišljao o problemu?!), ali jednako netočan. Ipak, ponovno zadivljuje razumijevanje konteksta upita, kao i rašlanjenje problema na podslučajeve.

There is not enough information to determine who is the knight, who is the knave, and who is the spy. Here is why:

If Alex is the knight, then his statement about Cody being

a knave must be true.¹⁴⁷ In that case, Ben's statement about Alex being a knight must also be true, since the knight always tells the truth. But then Cody's statement about being the spy must be a lie, since the knave always lies¹⁴⁸

This is a contradiction¹⁴⁹, because we assumed that Alex is the knight and therefore his statement about Cody being a knave is true.

If Alex is the knave, then his statement about Cody being a knave must be a lie. In that case, Ben's statement about Alex being a knight must also be a lie, since the knave always lies. But then Cody's statement about being the spy must be true, since the knave always lies and we assumed that Alex's statement about Cody being a knave is a lie. This is also a contradiction, because we assumed that Alex is the knave and therefore his statement about Cody being a knave is a lie.

The same logic applies if we assume that any of the other people is the knight or the knave.

Therefore, it is not possible to determine who is the knight, who is the knave, and who is the spy based on the given information.


Kad smo se već spomenuli Raymonda Smullyana, za čitatelje koji to možda ne znaju, riječ je o svestranom znanstveniku i umjetniku (matematičaru, logičaru, pijanistu, filozofu i mađioničaru), koji je iza sebe ostavio golem opus znanstvenih radova i knjiga na temu simboličke logike, posebice kombinatorne, algoritamske nerješivosti

¹⁴⁷ Istina.

¹⁴⁸ Također istina, stoga Cody može biti samo lažac (laže da je smutljivac, a ne može biti istonoljubac, jer je to po pretpostavci Alex), slijedom čega je Ben smutljivac. Sustav je bio na korak do valjanog rješenja, ali se odlučio za „kontradikciju“ ..

¹⁴⁹ Kontradikcije nema! Ostatak analize odgovora ostavljamo čitatelju.

formalnih sustava te samoreferentnosti u takvim sustavima.



SLIKA 4-40: Raymond Smullyan.
(preuzeto s poveznice <https://www.doverpublications.com/raymondsmullyan/>)


Za više detalja vidjeti, primjerice: https://en.wikipedia.org/wiki/Raymond_Smullyan. Čitatelju svakako preporučamo knjigu logičkih zagonetki (i ne samo) *To mock a mockingbird* (*Oponašati pticu rugalicu*).

Priča s ChatGPT-om¹⁵⁰ ovdje ne završava. Zapravo, tek počinje, doslovce i u prenesenom značenju!

Ovaj put ChatGPT dobio je zadaću modelirati samoreferentnu logičku zagonetku iz Primjera 4-18 u F-logici te je zatim pretočiti u interpreter Flora-2. Autor je bio uvjeren da ChatGPT o F-logici ne zna ni „F“. Ali, ... (slijedi dio razgovora, uz nešto komentara, ispravaka autorova pogrešnog engleskoga i skraćivanja segmenata generiranog kôda). Od čitatelja se ne očekuje razumijevanje kôda, iako ga je slijedom dosadašnjih primjera done-

¹⁵⁰ Sada u verziji 3.5. A već se pojavila i verzija 4.0.

kle mogao i steći. Njegova svrha je uvjeriti ga da sustavi kao što je ChatGPT, iako zapravo u vrlo ranoj fazi razvoja, već sada nisu igračke te će tijekom vrlo kratka vremena postati nezamjenjivi pomoćnici u svim vrstama kreativnih poslova. Ulomci kôda ovdje ne služe plašenju čitatelja, već ilustraciji složenosti s kojom je sustav kadar nositi se. Čitatelj ga može zanemariti i usredotočiti se samo na dijalog.

MC	Could you suggest an F-logic model for solving self-referential puzzles?
	F-logic (Frame Logic) is a knowledge representation language that is suitable for modeling complex systems and reasoning about them. Self-referential puzzles are a type of logic puzzle that involve statements that refer to themselves, such as the classic "liar paradox."
MC	<p>What about the following self-referential puzzle in Flora-2 F-logic syntax (not a Hilog one!)? Could you, please, model the self-referential puzzle below in F-logic syntax?</p> <ol style="list-style-type: none"> 1. What is the answer to the second question? <ol style="list-style-type: none"> A. A B. B C. C D. D 2. How many correct answers are B? <ol style="list-style-type: none"> A. 0 B. 1 C. 2 D. 3 3. Is there a question with the correct answer A? <ol style="list-style-type: none"> A. No B. Yes, 1 C. Yes, 2 D. Yes, All 3



Sure, here's one way to model the self-referential puzzle in Flora-2 F-logic syntax:

```
/** Define the set of questions */  
  
q(1).  
q(2).  
q(3).  
  
/** Define the set of possible answers for each question */  
ans(1, a).  
ans(1, b).  
ans(1, c).  
ans(1, d).  
  
ans(2, a).  
ans(2, b).  
ans(2, c).  
ans(2, d).  
  
ans(3, a).  
ans(3, b).  
ans(3, c).  
ans(3, d).  
  
/** Define the relation between questions and answers */  
  
true_ans(Q, A) :- ans(Q, A), forall(ans(Q, A1), A = A1).  
  
/** Define the questions and their answers */  
  
question(1, A) :- true_ans(2, A).  
question(2, b) :- count_ans(b, N), N = 1.  
question(3, a) :- true_ans(1, a).  
  
/** Define the rule for counting the number of correct answers */  
  
count_ans(A, N) :- ans(Q, A), true_ans(Q, A), N = #count{Q : ans(Q, A)}.
```

This F-logic model defines the set of questions and their possible answers, and then defines a relation '**true_ans(Q, A)**' that maps each question to its true answer. The '**question(Q, A)**'

	<p>predicate is then defined for each question as a rule that depends on the true answer(s) for that question and any other constraints that the question imposes.</p> <p>For example, the rule for question 1 states that its answer 'A' is the true answer for question 2. The rule for question 2 states that its answer is 'b' and that there is exactly one correct answer of 'b' among all the possible answers for question 2. The rule for question 3 states that its answer is 'a' and that the true answer for question 1 is 'a'.</p> <p>Finally, the 'count_ans(A, N)' predicate is defined as a rule that counts the number of correct answers for a given answer option 'A'. This predicate is used in the rule for question 2 to enforce the constraint that there is exactly one correct answer of 'b'.</p>
MC	<p>Yes, but it was a more Prolog like solution. What would it be in Flora-2 "pure" F-logic syntax?</p>
	<p>Certainly! Here is the Flora-2 "pure" F-logic syntax for the self-referential puzzle:</p> <pre> /** Define the frame types */ frameType question. frameType answer. /** Define the frame slots */ slot question_text : question. slot correct_answer : question -> answer. slot answer_text : answer. slot is_correct : answer -> boolean. /** Define the frames for each question and answer */ question(1)[question_text->"What is the answer to the second question?", correct_answer->answer(2)]. question(2)[question_text->"How many correct answers are B?", correct_answer->answer(b)]. question(3)[question_text->"Is there a question with the correct answer A?", correct_answer->answer(a)]. </pre>


```

answer(a)[answer_text->"A", is_correct->>true].
answer(b)[answer_text->"B", is_correct->>false].
answer(c)[answer_text->"C", is_correct->>false].
answer(d)[answer_text->"D", is_correct->>false].

/** Define the rules */

true_answer(Q, A) :- question(Q)[correct_answer->A], answer(A)[is_correct->true].

count_correct_answers(A, N) :- answer(A)[is_correct->true, count->N].

question(Q)[answer_text->A] :- true_answer(2, A), Q=1.
question(Q)[answer_text->b] :- count_correct_answers(b, 1), Q=2.
question(Q)[answer_text->a] :- true_answer(1, a), Q=3.



```



In this model, we define two frame types, 'question' and 'answer', and then define the slots for each frame type. We create frames for each question and answer, with the appropriate text and true/false value for the answer. The 'true_answer(Q, A)' predicate maps each question to its true answer, while 'count_correct_answers(A, N)' counts the number of correct answers for a given answer option.




Finally, we define the 'question(Q)[answer_text->A]' predicate for each question as a rule that depends on the true answer(s) for that question and any other constraints that the question imposes. For example, the rule for question 1 states that its answer 'A' is the true answer for question 2. The rule for question 2 states that its answer is 'b' and that there is exactly one correct answer of 'b' among all the possible answers for question 2. The rule for question 3 states that its answer is 'a' and that the true answer for question 1 is 'a'.


MC

So, what would be the solution to this puzzle?

	Based on the F-logic model I provided earlier, the solution to the self-referential puzzle is:
	<ol style="list-style-type: none"> 1. What is the answer to the second question? <ul style="list-style-type: none"> • Answer: C 2. How many correct answers are B? <ul style="list-style-type: none"> • Answer: 1
	<ol style="list-style-type: none"> 3. Is there a question with the correct answer A? <ul style="list-style-type: none"> • Answer: Yes, question 1 has the correct answer A.
MC	I'm afraid, but it seems not to be a true solution!
	<p>I apologize for any confusion. After reviewing the F-logic model I provided earlier, I discovered an error in the rule for question 1. The rule should be:</p> <p>question(Q)[answer_text->A] :- true_answer(Q, A), Q=1.</p> <p>With this corrected rule, the updated solution to the self-referential puzzle is:</p> <ol style="list-style-type: none"> 1. What is the answer to the second question? <ul style="list-style-type: none"> • Answer: C 2. How many correct answers are B? <ul style="list-style-type: none"> • Answer: 1 3. Is there a question with the correct answer A? <ul style="list-style-type: none"> • Answer: Yes, question 3 has the correct answer A.
MC	Answer to the question 1. is not a true one!

	<p>I apologize for the confusion. You are correct that the previous answer I provided was incorrect.</p> <p>Upon reviewing the F-logic model and double-checking the rules, I found another error. The correct rule for question 1 should be:</p> <pre>question(1)[answer_text->A] :- true_answer(2, A).</pre> <p>With this corrected rule, the updated solution to the self-referential puzzle is:</p> <ol style="list-style-type: none"> 1. What is the answer to the second question? <ul style="list-style-type: none"> • Answer: C 2. How many correct answers are B? <ul style="list-style-type: none"> • Answer: 1 3. Is there a question with the correct answer A? <ul style="list-style-type: none"> • Answer: Yes, question 3 has the correct answer A. <p>Once again, I apologize for any confusion caused by my earlier responses.</p>
<p>MC</p>	<p>What about the answer A to the first question?</p>
	<p>I apologize for the confusion. You are correct that the answer to the first question is actually A, not C. The updated rule for question 1 should be:</p> <pre>question(1)[answer_text->A] :- true_answer(2, A).</pre> <p>With this corrected rule, the solution to the self-referential puzzle is:</p> <ol style="list-style-type: none"> 1. What is the answer to the second question? <ul style="list-style-type: none"> • Answer: A 2. How many correct answers are B? <ul style="list-style-type: none"> • Answer: 1 3. Is there a question with the correct answer A? <ul style="list-style-type: none"> • Answer: Yes, question 3 has the correct answer A. <p>Thank you for bringing this to my attention and I apologize for any confusion caused by my earlier responses.</p>
<p>MC</p>	<p>What is a unique B's true answer?</p>

	<p>Based on the F-logic model I provided earlier, there is exactly one correct answer for question 2 that is B. The rule for question 2 states:</p> $\text{question}(2)[\text{answer_text} \rightarrow B] :- \text{true_answer_count}(B, C), C=1.$ <p>This rule says that the answer to question 2 is B if and only if there is exactly one true answer that is B. Therefore, the unique true answer for question 2 is B.</p>
<p>MC</p>	<p>But then answer 1.B say that there were at least two B's true answers? Could it be?</p>
	<p>You are correct, my apologies for the confusion. I made an error in my earlier response. According to the F-logic model, the correct answer to question 2 is that there are no correct answers that are B. The rule for question 2 states:</p> $\text{question}(2)[\text{answer_text} \rightarrow A] :- \text{true_answer_count}(B, C), C=0.$ <p>This rule says that the answer to question 2 is A if and only if there are no true answers that are B. Therefore, the answer to the question "How many correct answers are B?" is 0, and there are no B's true answers.</p> <p>Thank you for bringing this to my attention, and I apologize for any confusion caused by my earlier responses.</p>
<p>MC</p>	<p>So, what is a new solution to the puzzle?</p>
	<p>Based on the updated F-logic model, the solution to the self-referential puzzle is:</p> <ol style="list-style-type: none"> 1. What is the answer to the second question? <ul style="list-style-type: none"> • Answer: A 2. How many correct answers are B? <ul style="list-style-type: none"> • Answer: 0 2. Is there a question with the correct answer A? <ul style="list-style-type: none"> • Answer: Yes, question 3 has the correct answer A. <p>Once again, I apologize for any confusion caused by my earlier responses, and I hope this updated solution is helpful to you.</p>
<p>MC</p>	<p>And, according to that, A had exactly zero true answers? Maybe, the problem with your reasoning is that the question 3 really asks "How many correct answers are A?", just like question 2.</p>

	<p>You are correct, my apologies for the confusion. The question 3 in the puzzle should indeed ask "How many correct answers are A?" rather than "Is there a question with the correct answer A?" as I previously stated.</p> <p>With that correction, the updated F-logic model and solution to the self-referential puzzle is:</p> <pre>question(1)[answer_text->A] :- true_answer(2, A). question(2)[answer_text->A] :- true_answer_count(B, C), C=0. question(3)[answer_text->A] :- question(1)[true_answer->A].</pre> <ol style="list-style-type: none"> 1. What is the answer to the second question? <ul style="list-style-type: none"> • Answer: A 2. How many correct answers are B? <ul style="list-style-type: none"> • Answer: 0 3. How many correct answers are A? <ul style="list-style-type: none"> • Answer: 1 <p>Once again, I apologize for any confusion caused by my earlier responses, and I hope this updated solution is helpful to you.</p>
<p>MC</p>	<p>That contradicts with your answer to question 2?</p>

Nakon toga ChatGPT počeo je ponavljati jedno te isto netočno rješenje i tu je razgovor stao.

Tijekom ponovljenog razgovora i nakon popriličnog broja interakcija i ukazivanja na pogreške sustav je oblikovao valjan model i dao točno rješenje i zatim ga dvaputa stilski preoblikovao prema želji autora!

Iz navedenih razgovora sa sustavom ChatGPT autor zaključuje sljedeće:

- ChatGPT izvrsno razumije kontekst problema koji mu se zada modelirati i riješiti, čak i u slučajevima vrlo ezoteričnih sustava kakav je F-logika i njezinih implementacija.
- U Modeliranju problema vrlo je fleksibilan i u kratkom

vremenu kadar je proizvesti u idejnom smislu vrlo oprečne modele (u konkretnom slučaju F-logike: više Hiloga, više objektne orijentacije, više konstrukata *objekt-metoda-vrijednost*), ali u okvirima ograničenja koje nameće sintaksa jezika (ovdje sustava Flora-2). Za svakog modelara (logičara, programera,...) to je dragocjeno jer ga uči različitim pristupima modeliranju i rješavanju problema, a u interakciji sa sustavom to može olakšati i njemu samome (obostrano dobitna situacija).

- Usvaja korisnikove primjedbe koje ukazuju na nekonzistentnost rješenja ako su valjane, a odbacuje ih ako nisu.
- Daje prilično detaljna i tečna objašnjenja svoga zaključivanja na govornom jeziku.
- Ponekad zna ući u začarani krug pogrešnog zaključivanja iz kojega ne zna izaći. Tada je najbolje s modeliranjem krenuti ispočetka.

Novo inačice sustava ChatGPT, a svjedočimo već četvrtoj, koju autor kani iskušati čim dođe na red na listi čekanja, zasigurno će biti još bolja.

Sam sustav F-logike, impementiran u jeziku/alatu Flora-2 (besplatan), vrlo je upotrebljiv, gotovo idealan, pogotovo u sprezi sa sustavima kao što je ChatGPT, kao alat za modeliranje velikih sustava krajnje složene semantičke strukture. Vidimo ga u modeliranju zakona (koji onda neće trebati „tumačiti“, već samo „čitati“) semantičkom sažimanju sudskih slučajeva (spisa,...), koji onda neće brojati tisuće, već samo desetke ili koju stotinu stranica, modeliranju poslovnih pravila, modeliranju svih vrsta scenarija,

uključujući i scenarije igara, posebice epistemičkih, i općenito, modeliranju svih vrsta sustava znanja, kako monotone, tako i nemonotone^{151, 152} strukture, uključujući strukturiranje znanstvenih radova u smislu pripreme materijala, organiziranja hipoteza, provjere rezultata, itd.

F-logika je istaknut primjer visoko sofisticiranog sustava namijenjenom deklarativnom modeliranju i rješavanju problema, ali riznica logičkih metoda umjetne inteligencije, kao što je čitatelj već zasigurno zamijetio, ni izdaleka njime ne završava.

Suradnjom sa sustavima kao što je ChatGPT i znanstvenicima u humanističkom području otvaraju se novi kreativni vidici. Kao primjer onoga što je do sada urađeno, spomenimo knjige (GPT-3¹⁵³ i Wurds, 2021), (Giansiracusa, 2021) i (GPT-3 i Drozd, 2022).

U prvoj knjizi, naslova *The Real World*, opisuje se stvaranje igre tipa RPG¹⁵⁴. Koautor, A. F. Wurds, piše da je 80% knjige djelo sustava GPT-3. U potonjoj knjizi, naslova *The Curator: Future of Human-AI Interaction*, M. Drozd ne predstavlja se kao autor, već kao *curator* (riječ najčešće znači *kustos*, ali u kontekstu knjige njezino značenje je više *administrator, mentor, nadglednik, upravnik*). Knjiga,

¹⁵¹ Dostupno u komercijalnoj inačici, ErgoAI, čija je godišnjaj licenca, usput budi rečeno, „sitniš“.

¹⁵² Nešto što je u sustavu u jednom trenutku istina, u drugome to više ne mora biti.

¹⁵³ Ako ranije nije spomenuto, GPT je akronim od *Generative Pre-trained Transformer*, po riječima proizvođača (čitatelj, pogađa, tvrtke OpenAI), autoregresijski je model prirodnog jezika, obučenog na 45 terabajta tekstualnih podataka i 175 milijardi parametara.

¹⁵⁴ *Role Playing Game*, tip igre u kojoj igrač ili više njih igru igraju *iznutra*, kao njezini sudionici.

koju je, ponovimo, sukladno uputama M. Drozda napisao sustav GPT-3, a ilustrirao DALL•E 2, u suštini govori o tome kako napisati knjigu uz pomoć istog tog sustava GPT-3!

Naravno, da bi se sustavi kao što je ChatGPT mogli uspješno koristiti nužno će trebati poraditi na pojačanom usvajanju temeljnih znanstvenih disciplina koje stoje iza svakog ozbiljnog znanstvenog područja. Od ideje „*Mi u kompjutor, ChatGPT,..., ubacimo ..., a on nama izbací ...*“ nažalost neće biti puno vajde. *Ubacimo* li glupost ili kakve trice, još veće će *izací*.

Na kraju treba reći da sustavi iz riznice tvrtke OpenAI kojima smo se nakratko bavili, nisu jedini te vrste. Za još dva, vidjeti, primjerice, <https://alexasteinbruck.medium.com/explaining-the-code-of-the-popular-text-to-image-algorithm-vqgan-clip-a0c48697a7ff>, odnosno <https://stablediffusionweb.com/>.

O srodnim arhitekturama neuronskih mrežakoje stoje iza sustava ChatGPT i njemu srodnih te njihovoj primjeni naširoko piše i, primjerice, knjiga (Solanki i sur., 2021).

Neuronske mreže

Znatiželju čitatelja u pogledu neuronskih mreža, potaknutu prethodnim izlaganjima tijekom kojih je uglavnom bilo govora o njihovoj primjeni, utažit ćemo prikazom strukture i načina rada standardne arhitekture umjetne neuronske mreže, poznate kao *višeslojni perceptron* te zatim konvolucijskih neuronskih mreža kao temeljne arhitekture za procesiranje grafičkih podataka, dijelom prema blogu Ujjwala Karna (<https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/>), blogu Adita Deshpandea (<https://adeshpande3.github.io/>) te knjigama (Chollet¹⁵⁵, 2021) i (Kelleher, 2019). Za potrebe vizualizacije rada konvolucijske neuronske mreže koristit ćemo Web-aplikaciju Adama Harleya (https://adamharley.com/nn_vis/cnn/2d.html). Obje arhitekture ilustrirat ćemo na primjeru raspoznavanja rukom pisanih znamenaka iz baze MNIST. Pritom ćemo se ukratko upoznati sa širim razvojnim okružjem, u rasponu od najšire platforme (Anaconda), do neposrednog interaktivnog razvojnog okružja (Jupyter), preko najpopularnijeg programskog jezika za modeliranje neuronskih mreža (Python), specifičnih razvojnih okružja (TensorFlow) te biblioteke funkcija za njihovo brzo modularno prototipiranje (već spomenuta biblioteka Keras).

¹⁵⁵ Francois Chollet jedan je od vodećih znanstvenika u domeni neuronskih mreža i tzv. *dubokog učenja* (engl. *deep learning*). Autor je biblioteke funkcija *Keras*, ugrađene u vodeće jezike za modeliranje arhitektura neuronskih mreža kao što su *TensorFlow*, odnosno *PyTorch*. Biblioteka Keras omogućuje modularno strukturiranje neuronskih mreža, na način Lego kockica. Po autorovu sudu, knjiga *Deep Learning with Python* na koju se pozivamo, sada već u drugom, bitno proširenom izdanju, jedna je od ponajboljih svoga roda.

Temeljna arhitektura umjetne neuronske mreže: višeslojni perceptron

Prije negoli se upustimo u izlaganje konvolucijskih neuronskih mreža, nužno je nešto reći o općoj ideji procesiranja podataka neuronskim mrežama i njihovom temeljnom modelu, tzv. *višeslojnom perceptronu*. Zadržat ćemo se na konceptualnoj ideji, bez ulaza u tehničke detalje. Čitatelj će ih lako pronaći u bezbroj knjiga, članaka, blogova, čak i na hrvatskom jeziku. Izdavačka kuća MATE iz Zagreba objavila je niz prijevoda na hrvatski jezik knjiga iz serije *Essential knowledge* ((Kelleher, 2019), (Kelleher i Tierney), (Alpaydin, 2016), (Ceruzzi, 2012) i (Denning i Tedre, 2019)) izdavača MIT Press, na temu podatkovne znanosti, strojnog i dubokog učenja, povijesti računalstva i tzv. *računalnog razmišljanja*.

U članku (Tappert, 2019), nakon provedene analize doprinosa znanstvenika, uglavnom s engleskog govornog područja¹⁵⁶, autor zaključuje da utemeljiteljem arhitekture perceptrona treba smatrati F. Rosenblatta, uz odavanje priznanja i njegovim prethodnicima, W. McCullochu, W. R. Ashbyu i D. Hebbu. U negativnom kontekstu spominje se inače izvrsna knjiga (Minsky and Papert, 1969), u kojoj, uz puno drugih vrlo vrijednih rezultata, autori dokazuju da dvoslojni perceptron s učenjem putem povratne veze nad inicijalnim skupom težinskih koeficijenata ne može modelirati nelinearne transformacije, točnije logičku funkciju *ekskluzivno ili* (*A ili B*, ali ne oboje istodobno) O tome više nešto kasnije.


U svjetlu ranije napomene treba napomenuti da je ukrajinski/ruski (atribucije se razlikuju od reference do reference) znanstvenik Jurij Ivakhnenko već 1966. g. objavio rad u časopisu *Soviet*

¹⁵⁶ Stoga sve te podatke treba uzeti „sa zrnom soli“..

Automatic Control, na temu tzv. *grupne obrade podataka*, u kojem je pokazao kako se ona može upotrijebiti za obučavanje neuronske mreže s osam slojeva neurona i time Minskyev i Papertov prigovor učinio bespredmetnim. S obzirom na to, i Ivakhnenko bi se mogao smatrati utemeljiteljem neuronskih mreža u suvremenom smislu. Dostupniji rad koji izlaže Ivanenkhovu metodu i njezine brojne i značajne primjene je (Farlow, 1981).

Ideja višeslojnog perceptrona jest oponašati procesiranje podataka (električnih signala) na način na koji to radi ljudski mozak. Osnovna slika o strukturi i funkcioniranju neurona u ljudskom mozgu (i ne samo) stvorena je kroz dugotrajna fiziološka i neurološka istraživanja. Sljedeća slika krajnje grubo prikazuje njegovu strukturu.

Slika pokazuje da biološki neuron ima trodijelnu strukturu (tijelo stanice, ulazne veze (dendrite) i izlaznu vezu (akson)). Prema relevantnim izvorima ljudski mozak broji oko sto milijardi neurona, raspodijeljenih u golem broj funkcionalnih jedinica (nakupina).

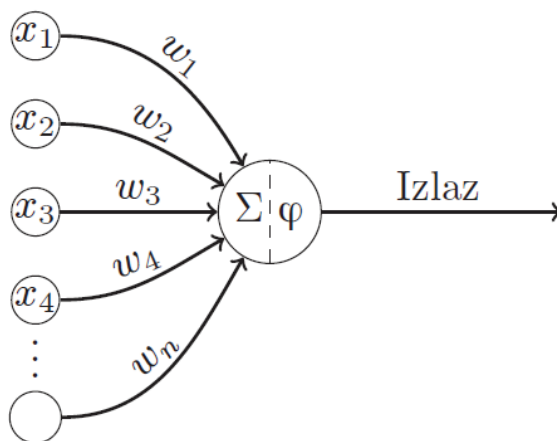


SLIKA 4-41: Grubi prikaz biološkog neurona (preuzeto iz (Kelleher, 2021)).

Neuroni djeluju tako da stanično tijelo električne signale različite jakosti „zbraja“ i ako rezultirajući signal premaši određeni prag, prosljeđuje ga kroz akson i dendrite koji se na njega nastav-

ljaju, drugim neuronima. Taj izlazni signal naziva se akcijskim potencijalom, što će reći da neuron djeluje kao okidač tipa *sve-ili-ništa*.


Struktura i način djelovanja umjetnog neurona kao temeljnog gradivnog elementa svih neuronskih mreža nastala je apstrakcijom strukture i svojstava biološkog neurona i njegovog funkcionalnog opisa, kao na sljedećoj slici (Kelleher, 2021).



SLIKA 4-42: Prikaz umjetnog neurona (preuzeto iz (Kelleher, 2021))

Ulazni podaci, x_1, x_2, \dots , množe se odgovarajućim težinama, w_1, w_2, \dots , sumiraju i ta se suma prije „okidanja“ (prosljeđivanja drugim neuronima) preoblikuje tzv. *nelinearnom aktivacijskom funkcijom*. Time se rješava Minskyev i Papertov prigovor. U suprotnom, s obzirom da i sljedeći neuroni u nizu podatke procesiraju na isti način, nikada se ne bi izašlo iz domene linearnih funkcija, jer je njihovo uzastopno slaganje (kompozicija) opet linearna funkcija, pa bi raspoznavanje objekata, što je jedna od najčešćih zadataka višeslojnog perceptrona, bilo neprecizno, ili čak nemoguće. Pokazuje to zorno Slika 4-43 (Kelleher, 2021), koja u dualnom logičko/


geometrijskom prikazu opisuje dvodimenzionalne tablice istinitosti (semantičke tablice) logičkih veznika/funkcije AND („i“), OR („ili“) i XOR („ekskluzivno/isključivo ili“). Vizualno je jasno da ni jedan pravac (dužina) ne može u slučaju potonje razdvojiti vrijednosti T (*istina*) i F (*laž*), dok je za prva dva logička veznika to moguće.



SLIKA 4-43: Ilustracija prigovora Minskya i Paperta (preuzeto iz (Kelleher, 2021)).

Mnoštvo je tipova nelinearnih aktivacijskih funkcija (sigmoidna, tangens hiperbolni, po dijelovima linearne (*RELU-rectified linear unit*)), itd. Iskustvo primjene neuronskih mreža i teorijska istraživanja pokazali su da su za različite potrebe prikladne različite aktivacijske funkcije. Čest je slučaj da svi neuroni umjetne neuronske mreže koriste istu aktivacijsku funkciju, ali i slučaj da se ona mijenja od sloja do sloja neurona.


Najkasnije u srednjoj školi doznali smo da je graf linearne funkcije $y=ax$ pravac koji prolazi ishodištem koordinatnog sustava. To da on prolazi ishodištem za razdvajanje pojedinih objekata u dvodimenzionalnom koordinatnom sustavu (slici/prikazu/mapi), predstavlja otegotnu okolnost. Stoga se linearnoj funkciji kao sumi umnožaka ulaznih podataka u neuron odgovarajućim težinama dodaje tzv. *pristranost* (engl. *bias*), prikazuje Slika 4-44.



SLIKA 4-44: Prikaz umjetnog neurona s pristranošću (preuzeto iz (Kelleher, 2021)).

Povezivanjem umjetnih neurona u slojeve, nastaje višeslojni perceptron, Slika 4-45, (Kelleher, 2021).

Višeslojni perceptron često se zove i *potpuno povezanom* neuronskom mrežom, jer svi ulazni podaci ulaze u sve neurone prvog skrivenog sloja, a svaki od njih povezan je sa svim neuronima sljedećeg sloja, sve do izlaznog sloja, koji može imati jedan ili više izlaza.




SLIKA 4-45: Prikaz višeslojnog perceptrona,preuzeto iz (Kelleher, 2021).

Višeslojni perceptron namijenjen je tzv. *nadgledanom učenju*. U prvoj iteraciji procesiranja ulaznih podataka težine se inicijaliziraju slučajnim načinom, što rade odgovarajući algoritmi. Aktivacijska funkcija zadnjeg skrivenog sloja bira se ovisno o zadaći koju mreža rješava. Ako je svrha ulazni objekt svrstati u jednu od konačnog broja kategorija (mačka, pas ptica,...), onda se koristi funkcija *softmax*, poznata i kao *normalizirana eksponencijalna funkcija*, koja daje vjerojatnost da ulazni objekt pripada jednoj od predviđenih kategorija. Jasno je da je vrlo malo izgledno da se pogodak dogodi „odprve“. Pored toga, cilj mreže nije valjano raspoznati samo pojedinačne objekte iz dane kategorije objekata, već *sve* njezine objekte (*sve* mačke, ptice,...) Stoga je potrebno izračunati *pogrešku klasifikacije*, poznatu i kao *funkcija gubitka* (engl. *loss function*) za svaki pojedinačni objekt i zatim je uprosječiti za sve objekte koji se mreži predočuje u procesu njezina obučavanja. To se zove *funkcija troška* (engl. *cost function*). Ona se najčešće računa kao prosjek kvadrata odstupanja između numeričke vrijednosti rezultata klasifikacije koje daje mreža i stvarnih poznatih vrijednosti¹⁵⁷. Cilj obučavanja mreže je minimizirati funkciju troška. To se radi metodom tzv. *gradijentnog spusta* (engl. *gradient descent*) u sprezi s algoritmom *prosljeđivanja pogreške unatrag* (engl. *back-propagation*).

Za pogrešku izlaza neuronske mreže zaslužne su težine veza i iznosi pristranosti između pojedinačnih neurona u mreži. Primjerice, ako su težine u sloju neurona koji prethodi izlaznom sloju bile prevelike, onda će one rezultirati prevelikom pogreškom klasifikacije, što znači da ih treba smanjiti, pritom (uz neka ograničenja tehničke

¹⁵⁷ To i znači da je obučavanje mreže *nadgledano*.

naravi, o kojima ovdje nećemo govoriti) što brže. Za *brže* zadužena je metoda gradijentnog spusta. *Spuštanje* se odvija niz plohu pogreška/plohu troška klasifikacije kao funkciju težina. U slučaju dviju težina ta je ploha nalik *zdjeli* (engl. *dish*), kao na Slici 4-46.



SLIKA 4-46: Ploha pogreške neuronske mreže s dvije težine.
(preuzeto s <https://www.cs.umd.edu/~tomg/projects/landscapes/>)

Cilj je što *strmiji* (ali i izbjegavanje određenih zamki koje to nosi) spust do dna plohe, tj. minimuma funkcije troška. Strminu spusta, za svaku težinsku varijablu, određuje brzina promjene njezine vrijednosti, koja se, kao što je poznato, računa kao parcijalna derivacija funkcije troška po toj varijabli.

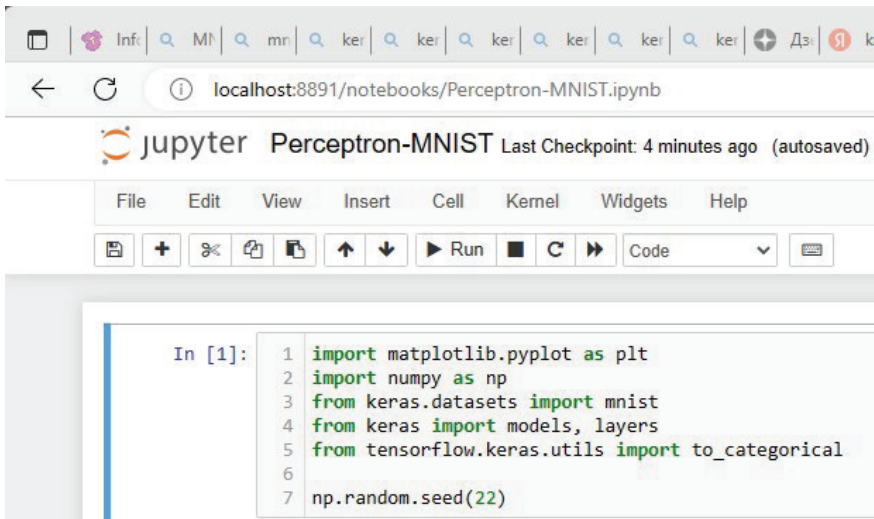
Za samo ažuriranje težina zadužen je, kako je već rečeno, algoritam prosljeđivanja pogreške unatrag. Nova vrijednost težine računa se kao razlika između stare vrijednosti i promjene gradijenta funkcije troška, izračunate za staru vrijednost težine i pomožene s tzv. *stopom učenja* (engl. *learning rate*), što je vrijednost u intervalu $(0, 1)$, često jednaka 0,1.

Za prosljeđivanje pogreške u dublje slojeve mreže koristi se pravilo lančanog parcijalnog deriviranja.

Ovime smo vrlo ugrubo, izbjegavajući niz tehničkih (i ne samo) detalja i matematičke formule, opisali osnovnu arhitekturu višeslojnog perceptrona. Za šire i detaljnije upoznavanje, uključujući matematički aparat (ako to želi), čitatelju preporučamo knjigu (Kelleher, 2021) u engleskom izvorniku ili hrvatskom prijevodu.

Međutim, kao što nije potrebno poznavati detaljnu strukturu automobila (motor, elektroniku,...), tako nije potrebno (ali je dobro) detaljno poznavati arhitekturu neuronskih mreža da bi se one uspješno koristile za rješavanje različitih problema. Dovoljno je poznavati alate visoke razine za njihovo modeliranje.

Jedan od tih problema, nastao slijedom potreba prakse, jest prepoznavanje rukom pisanih znamenaka. Ovdje izlažemo programski kôd (prema poveznici <https://www.stefanfiott.com/machine-learning/mnist-using-keras/>) koji implementira višeslojni perceptron (potpuno povezanu neuronsku mrežu) u razvojnom okružju Anaconda/Jupyter i programskom okružju Python/TensorFlow/Keras. Dodana je naredba za sažeti prikaz mreže (`network.summary()`) Također su promijenjene vrijednosti nekih parametara kako bi se skratio zapis rezultata. Kôd koristi bazu znamenaka MNIST. Komentari su autorovi.



Prikaz sučelja Anaconda/Jupyter, s otvorenom interaktivnom radnom bilježnicom (Jupyter Notebook), imena Perceptron-MNIST. Programski kod piše se u ćelijama poput gornje i može se pokretati interaktivno, pod određenim uvjetima i „napreskok“. U ćeliji [1] učitane su nužne biblioteke (*matplotlib*-*crtanje grafike*, *numpy*-*numerički izračuni*), baza znamenaka MNIST, biblioteke modela i slojeva budućeg perceptrona, klasifikator (znamenaka) *to_categorical* i, na kraju, *sidro* generatora slučajnih brojeva u okviru biblioteke *numpy* (skraćeno *np*).

```
In [2]: 1 (train_images, train_labels), (test_images, test_labels) = mnist.load_data()
```


Učitavanje slika znamenaka za obučavanje, odnosno testiranje buduće neuronske mreže iz baze MNIST.

```
In [3]: 1 print(train_images.shape)
2 print(len(train_labels))
3 print("First 10 labels: {0} -> {1}".format(train_labels[:10], type(train_labels[0])))

(60000, 28, 28)
60000
First 10 labels: [5 0 4 1 9 2 1 3 1 4] -> <class 'numpy.uint8'>
```

Za potrebe *testiranja* mreže iz baze MNIST učitano je 10000 ručno ispisanih slika znamenaka, svaka dimenzije 28x28 točaka. Ispisano je njih prvih deset.

```
In [5]: 1 num_plot_digits = 3
2 digits_to_plot = np.random.randint(0, 60000, num_plot_digits)
3 fig, axes = plt.subplots(1, 3, figsize=(12,2))
4
5 for i in range(num_plot_digits):
6     axes[i].imshow(train_images[digits_to_plot[i]], cmap=plt.cm.binary)
7     axes[i].set_title(train_labels[digits_to_plot[i]])
8     axes[i].set_xticks([])
9     axes[i].set_yticks([])
```



Slučajnim izborom (naredba `np.random.randint()`) biraju se slike triju znamenaka iz baze MNIST i ispisuju u dvostrukoj veličini. Naredbe [5:8-9] uklanjaju numeričke oznake mjernih jedinica na osima (donjem i lijevom okviru slike).

```
In [6]: 1 network = models.Sequential()
2 network.add(layers.Dense(512, activation='relu', input_shape=(28 * 28, )))
3 network.add(layers.Dense(10, activation='softmax'))
4 network.compile(optimizer='rmsprop',
5                 loss='categorical_crossentropy',
6                 metrics=['accuracy'])
```

[6:1]: Perceptron (network) gradi se kao linearan slijed slojeva neurona (`Sequential()`)

[6:2]: Dodaje se prvi sloj od 512 neurona (potencija broja 2!) od kojih će svaki biti povezan sa svakom točkom slike znamenke koja se procesira. Aktivacijska funkcija je razlomljena linearna funkcija RELU (u konačnici nelinearna!). Dimenzije ulaznih slika su 28x28 točaka.

[6:3]: Dodaje se izlazni sloj od 10 neurona (za 10 znamenaka), povezanih sa svim neuronima prethodnog sloja (svaki sa svakim). Aktivacijska funkcija je *softmax*, koja ulazni vektor numeričkih vrijednosti normalizira (u granice od 0 do 1) i prikazuje kao distribuciju vjerojatnosti (u ovom slučaju procesirane (slike) znamenke).

```
In [9]: 1 network.fit(train_images, train_labels, epochs=5, batch_size=128)

Epoch 1/5
469/469 [=====] - 2s 5ms/step - loss: 0.2569 - accuracy: 0.9256
Epoch 2/5
469/469 [=====] - 2s 5ms/step - loss: 0.1033 - accuracy: 0.9694
Epoch 3/5
469/469 [=====] - 2s 5ms/step - loss: 0.0676 - accuracy: 0.9797
Epoch 4/5
469/469 [=====] - 2s 5ms/step - loss: 0.0488 - accuracy: 0.9855
Epoch 5/5
469/469 [=====] - 2s 5ms/step - loss: 0.0368 - accuracy: 0.9888
```

Out[9]: <keras.callbacks.History at 0x1b854717d30>

[6:4-6]: Optimizator, *rmsprop* (Mean Square Propagation - korijen iz prosjeka kvadrata odstupanja vrijednosti varijable od njezine srednje vrijednosti)), funkcija koja ažurira model

```
In [10]: 1 test_loss, test_acc = network.evaluate(test_images, test_labels)
2 print('loss: {0:.4f} - acc: {1:.4f}'.format(test_loss, test_acc))

313/313 [=====] - 1s 1ms/step - loss: 0.0645 - accuracy: 0.9810
loss: 0.0645 - acc: 0.9810
```

perceptrona kroz algoritam povratnog širenja pogreške kalsifikacije u sprezi s algoritmom gradijentnog spusta. Funkcija troška, *loss* (mjeri kvalitetu izlaza perceptrona), je *categorical_crossentropy*. Učinkovitost obučavanja perceptrona (metrics) ovdje je *accuracy*, tj. omjer točno i netočno klasificiranih znamenaka u svakoj iteraciji obučavanja perceptrona. Za više detalja vidjeti (Cholett, 2021).

```
In [7]: 1 network.summary()

Model: "sequential"

Layer (type)                 Output Shape              Param #
-----
dense (Dense)                 (None, 512)               401920
dense_1 (Dense)                (None, 10)                5130
-----
Total params: 407,050
Trainable params: 407,050
Non-trainable params: 0
```

Sažetak (modela) perceptrona: dva sloja (dense i dense_1) tipa Dense (potpuno povezani slojevi), s brojem parametara (težine i pristranosti), $28 \times 28 \times 512 + 512 = 401408$ ukupno, odnosno $512 \times 10 + 10 = 5130$. Ukupno 407050 parametara, što je priličan broj i za ovakvu krajnje jednostavnu mrežu.

```
In [8]: 1 train_images = train_images.reshape((60000, 28 * 28))
2 train_images = train_images.astype('float32') / 255
3
4 test_images = test_images.reshape((10000, 28 * 28))
5 test_images = test_images.astype('float32') / 255
6
7 train_labels = to_categorical(train_labels)
8 test_labels = to_categorical(test_labels)
```

Slike znamenaka, s vrijednostima (nijanse sive boje) točaka u rasponu od 0 do 255 pretvaraju se u decimalne vrijednosti u rasponu između 0 i 1, a njihove oznake (labels) u binarni ekvivalent (vektor duljine 10), s jedinicom na poziciji za jedan manjom (zbog početnog indeksa 0)

od vrijednosti oznake.

Rezultati vrednovanja obučavanja mreže, mjereni istom mjerom, na testnom skupu znamenaka. Vidi se da je učinkovitost raspoznavanja nešto niža, ali još uvijek dobra.

Rezultati vrednovanja obučavanja mreže, mjereni istom mjerom, na testnom skupu znamenaka. Vidi se da je učinkovitost raspoznavanja nešto niža, ali još uvijek dobra.

Rezultati vrednovanja obučavanja mreže, mjereni istom mjerom, na testnom skupu znamenaka. Vidi se da je učinkovitost raspoznavanja nešto niža, ali još uvijek dobra.

Ovdje završavamo naše bavljenje višeslojnim perceptronom. Zainteresirani čitatelj naći će neizmjereno mnogo materijala na tu temu, uključujući i savjete oko kôda (kratke isječke kojima se ilustriraju pojedinačne naredbe i konstrukti Pythona ili drugog izabranog programskog jezika), pogreškama u kôdu, itd.

Da se neuronskih mreža ne trebaju bojati ni znanstvenici humanističke i općenito, društvene orijentacije, pokazuje i svijetao primjer bračnog para Frank. Izlaganje nastavljamo prikazom konvolucijskih neuronskih mreža.

Konvolucijske neuronske mreže

Izvorno, konvolucijske neuronske mreže razvijene su za potrebe prepoznavanja svih vrsta objekata na statičkim dvodimenzionalnim grafičkim prikazima (slikama, fotografijama,...), odnosno dinamičkim prikazima (pepoznavanje lica ljudi u pokretu na snimkama sigurnosnih kamera, prepoznavanje objekata u prometu za potrebe vozila s autonomnim upravljanjem,...). Danas se koriste i za puno drugih stvari, poput analize dokumenata, analize meteoroloških podataka prikupljenih kroz duga vremenska razdoblja, za potrebe analize klimatskih promjena uzrokovanih ljudskim djelovanjem i poduzimanje akcija da se one uspore, za finu analizu odnosa među ljudima kroz komunikaciju na društvenim

mrežama, za potrebe savjetovanja pri reklamiranju proizvoda, za predviđanje potresa, za potrebe medicinske dijagnostike, itd.

Teorijsku osnovu konvolucijske mreže nalaze u radovima (neuro)fiziologa. Posebno treba istaknuti rad D. H. Hubela i T. N. Wiesela na proučavanju vida kod mačaka, za koji su 1981. g. dobili Nobelovu nagradu za medicinu. U jednom od svojih istraživanja ovaj dvojac otkrio je da vizualni korteks mozga mačke reagira aktivacijom pojedinačnih skupina stanica (svaki put drugih) kad joj se prikaže vodoravno, uspravno, odnosno koso položena dužina. To je dovelo do ideje *filtra*, kao ekstrakcije pojedinačnih svojstava *slike* (zadržat ćemo se na dvodimenzionalnom slučaju).

U njihovo osnovi leži model klasične nadgledane neuronske mreže s učenjem kroz širenje pogreške unatrag.

(Chollet, 2021) izdvaja tri glavne zadaće tzv. *računalnog vida*, tj. semantičke analize dvodimenzionalnih grafičkih slika (okvirno rečeno). To su:

Klasifikacija slika—slici se pridjeljuje jedna ili više oznaka (kategorija). Kao primjer navodi se aplikacije za pretraživanje fotografija/slika Google Photos, iza koje stoji neuronska mreža koja objekte na njima klasificira u preko dvadeset tisuća različitih kategorija, često s više oznaka, obučena na milijunima slika.


Segmentacija slika—cilj je klasificirati ne cijelu sliku, već na njoj izdvojiti objekte različitih kategorija (segmente). To radi, recimo, svima poznati Zoom, u situaciji kada sudionik u komunikaciji koristi kameru, ali ne želi da se na videu koji ona emitira vidi išta iz njegova okružja doli njega samoga.

Detekcija objekata—željeni objekti uokviruju se pravokutnicima kako bi se jasnije istakli. Time se služe sustavi vizualnog

nadzora svih vrsta, uključujući i sustave autonomne vožnje.


Arhitektura konvolucijske neuronske mreže

Najvažniji pojam na koji se oslanja struktura konvolucijske neuronske mreže jest pojam *konvolucijskog filtra* (engl. *convolutional filter*), *jezgre* (engl. *kernel*) ili *svojstva* (engl. *feature*). Jedan vidimo na Slici 4-47. Ponegdje se u literaturi svojstvima zovu višedimenzionalne jezgre.




SLIKA 4-47: Konvolucijski filtar, u numeričkom i grafičkom zapisu.
(preuzeto s bloga Adita Deshpandea)

Pretpostavimo da tim filtrom očitavamo veću sliku, tj. da ga „preklapamo“ s jednakim područjem negdje na slici (Slika 4-48). Taj dio slike zovemo receptivnim poljem (engl. *receptive field*). Svrha filtra jest pojačati signal kada filtar na receptivnom polju pronade objekt sličan sebi.



SLIKA 4-48: Izvorna slika i ista slika preklpoljena filtrom.
(preuzeto s bloga Adita Deshpandea)

Ostaje pitanje kako filter to radi. Ilustriramo to na filteru sa Slike 4-48, s receptivnim poljem označenim žutim kvadratom, nad receptivnim poljem na izvornoj slici.



SLIKA 4-49: Receptivno polje s prethodne slike, njegova numerička reprezentacija i numerička reprezentacija filtra. (preuzeto s bloga Adita Deshpande)

*Konvolucija*¹⁵⁸ je matematička operacija koja redom množi vrijednosti tablice filtra s odgovarajućim vrijednostima tablice¹⁵⁹ receptivnog polja i dobivene vrijednosti zbraja. Većina umnožaka bit će jednaka nuli. To će biti slučaj sa svim umnošcima prvog retka obiju tablica, jer su od nule različite vrijednosti u „pogrešnim kućicama“, (1, 7), odnosno (1, 6). Drugi redak prve, odnosno druge tablice, dat će rezultat $50 \times 30 = 1500$ ($(2, 5)_1 \times (2, 5)_2$). Čitatelj se dalje već snalazi i zaključuje da je rezultat konvolucije izabranog filtra i izabranog perceptivnog polja jednak:


$$50 \times 30 + 20 \times 30 + 50 \times 30 + 50 \times 30 + 50 \times 30 = 6600,$$

što nije mali iznos! Ako bismo receptivno polje izabrali kao na sljedećoj slici, onda bi njegova konvolucija s istim filtrom kao rezultat

¹⁵⁸ Riječ *konvolucija* ima više značenja. U kontekstu neuronskih mreža značenje *preplitanje* (filtra i perceptivnog polja) bilo bi primjereno.

¹⁵⁹ U terminologiji neuronskih mreža tablice su *matrice* (dvodimenzionalne tablice), odnosno *tenzori* (višedimenzionalne matrice). Odatle naziv biblioteke za modeliranje neuronskih mreža TensorFlow.

dala vrijednost 0, što će čitatelj lako provjeriti. Zaključujemo da se polazni filtar jednostavno na drugom perceptivnom polju *nije prepoznao*, što je vizualno posve jasno. Konvolucijske neuronske mreže koriste istodobno više filtara. Taj broj u pravilu je jednak potenciji broja 2 (najčešće $2^4=16$, do $2^{10}=1024$), najčešće dimenzija 3×3 ili 5×5 .



SLIKA 4-50: Konvolucija novog receptivnog polja sa starim filtrom.
(preuzeto s bloga Adita Deshpandea)

Korištenje filtara nije počelo konvolucijskim neuronskim mrežama. Davno prije njihove pojave koristile su ga i aplikacije, kao što je Photoshop i njemu slične.

Filtri, poput prikazanih na slikama, ranije poznatiji kao *svojstva*, razvijani su „ručno“.



SLIKA 4-51: Izvorna slika cvijeta.
(preuzeto s poveznice <http://designstacks.net/convolution-matrix>)

Postojala je, i još uvijek postoji, znanstveno-inženjerska dis-

ciplina poznata kao *inženjerstvo svojstava*. (engl. *feature engineering*). Za detalje vidjeti, primjerice, (Duboue, 2020).



SLIKA 4-52: Primjena filtra za izoštrjenje slike (engl. *sharpen*).
(preuzeto s poveznice <http://designstacks.net/convolution-matrix>)




SLIKA 4-53: Primjena filtra za zamućenjeslike (engl. *blurr*).
(preuzeto s poveznice <http://designstacks.net/convolution-matrix>)



SLIKA 4-54: Primjena filtra za stvaranje reljefa slike (engl. *emboss*).
(preuzeto s poveznice <http://designstacks.net/convolution-matrix>)

Postavlja se pitanje kako oblikovati valjane filtre za potrebe neuronskih mreža. Dobra vijest je da se oni *slikaju sami* (kao nekoć akvareli slikarice Nite Engle (*How to Make a Watercolor Paint Itself: Experimental Techniques for Achieving Realistic Effects*). Ne baš, ali...), tako da se inicijaliziraju slučajnim vrijednostima prema normalnoj ili Gaussovoj distribuciji vjerojatnosti, a kasnije, u procesu obučavanja mreže, poprimaju svakojaka oblička, poput ovih na sljedećoj slici.



SLIKA 4-55: Vizualizacija stvarnih filtara konvolucijske neuronske mreže
(<https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/>)

Prvi sloj neurona konvolucijske neuronske mreže, konvolucijski sloj (prvi skriveni sloj neurona), nastaje tako da svaki filter „pluta“ nad danom slikom, najčešće kvadratnih dimenzija, počevši od gornjeg lijevog kuta, pomičući se svaki put za jedno ili više mjesta (parametar *stride* (*korak*, *posmik*)) udesno ili nadolje, sve dok ima za to mogućnosti, računajući svaki put vrijednost operacije konvolucije u sprezi s receptivnim poljem nad kojim se nalazi te, na kraju, pohranjuje tu vrijednost u novu matricu, točnije, tenzor. Prikazuje to sljedeća slika. Pojedine faze gradnje prvog skrivenog konvolucijskog sloja izrezane su iz animacije na poveznici <https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/>. Čitatelj je zasigurno zaključio da vrijednosti matrice filtra predstavljaju analog težina u slučaju perceptrona.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

1	0	1
0	1	0
1	0	1

Izvorna, crno-bijela slika (vrijednosti točaka su 0 i 1), dimenzije 5×5 i filter (također binarni), dimenzije 3×3.

1 _{x1}	1 _{x0}	1 _{x1}	0	0
0 _{x0}	1 _{x1}	1 _{x0}	1	0
0 _{x1}	0 _{x0}	1 _{x1}	1	1
0	0	1	1	0
0	1	1	0	0

4		

1	1 _{x1}	1 _{x0}	0 _{x1}	0
0	1 _{x0}	1 _{x1}	1 _{x0}	0
0	0 _{x1}	1 _{x0}	1 _{x1}	1
0	0	1	1	0
0	1	1	0	0

4	3	

Filter je postavljen ponad receptivnog polja ulazne slike, čije vrijednosti su označene znamenkama u većem fontu, a uza svaku od njih, u donjem desnom kutu, označeno je s kojom vrijednošću filtra se ona množi. Tako oznaka 1_{x1} na poziciji (2, 2) slike lijevo označava da se odgovarajuća vrijednost, 1, receptivnog polja na toj poziciji, množi s vrijednošću filtra na toj istoj poziciji. Kad se umnoški zbroje, dobiva se vrijednost 4. Kako to ide dalje, vidimo na sljedećim slikama.


1	1	1 _{x1}	0 _{x0}	0 _{x1}
0	1	1 _{x0}	1 _{x1}	0 _{x0}
0	0	1 _{x1}	1 _{x0}	1 _{x1}
0	0	1	1	0
0	1	1	0	0

4	3	4

1	1	1	0	0
0 _{x1}	1 _{x0}	1 _{x1}	1	0
0 _{x0}	0 _{x1}	1 _{x0}	1	1
0 _{x1}	0 _{x0}	1 _{x1}	1	0
0	1	1	0	0

4	3	4
2		

•
•
•



Prvi filtar daje prvu mapu svojstava prvog skrivenog sloja konvolucijske neuronske mreže. Svaki daljnji filtar (iste dimenzije) daje po još jednu takvu mapu. Sve tako dobivene mape svojstava slažu se jedna na drugu i zajedno, kao višedimenzionalna matrica (tenzor), predstavljaju prvi skriveni sloj konvolucijske mreže. Broj mapa predstavlja dimenziju konvolucijske mreže poznate kao *channel*.

Sljedeći skriveni sloj konvolucijske neuronske mreže nastaje tako da se svakoj mapi svojstava prvo pribroji vrijednost pristranosti, nako čega na nju djeluje aktivacijska funkcija, a nakon nje slijedi tzv. *združivanje* (engl. *pooling*). Svrha združivanja vrijednosti aktivacijskom funkcijom preoblikovane mape svojstava jest smanjenje dimenzije mape, uz očuvanje informacije koju ona sadrži te očuvanje fleksibilnosti (invarijantnosti) prepoznavanje objekata s obzirom na male pomake, rotacije i dilatacije.

Združivanje se obavlja tako da se kvadratna matrica izabrane dimenzije, često 2×2 , pomiče, bez preklapanja (najčešće), nad mapom svojstava, počinjući od gornjeg lijevog kuta udesno i prema dolje i očitava odgovarajuće vrijednosti te ih *združuje* u jednu. Združivanje se može obaviti na više načina:

- *Max Pooling* - bira najveću vrijednost
- *Min Pooling* - bira najmanju vrijednost
- *Average Pooling* - bira srednju vrijednost

Uz operacije konvolucije i združivanja vezani su određeni tehnički detalji i problemi izvan dosega ovoga izlaganja. U praksi, čitatelj o njima ne mora voditi brigu, osim u slučaju da mrežu razvija sam naredbama niske razine (TensorFlow,...).

Konvolucijska neuronska mreža gradi se slaganjem slojeva konvolucije i združivanja te, na kraju, dodavanjem slojeva potpuno povezanih neurona za potrebe krajnje klasifikacije

Konstrukcijom konvolucijskih neuronskih mreža čitatelj će najlakše ovladati koristeći biblioteku Keras. Ovdje, prema (Chollet, 2021), izlažemo primjer njezine konstrukcije za već znani nam problem raspoznavanja rukom ispisanih znamenaka iz baze MNIST.

```
from tensorflow import keras
from tensorflow.keras import layers
inputs = keras.Input(shape=(28, 28, 1))
x = layers.Conv2D(filters=32, kernel_size=3, activation="relu")(inputs)
x = layers.MaxPooling2D(pool_size=2)(x)
x = layers.Conv2D(filters=64, kernel_size=3, activation="relu")(x)
x = layers.MaxPooling2D(pool_size=2)(x)
x = layers.Conv2D(filters=128, kernel_size=3, activation="relu")(x)
x = layers.Flatten()(x)
outputs = layers.Dense(10, activation="softmax")(x)
model = keras.Model(inputs=inputs, outputs=outputs)
```

Ulazni podaci opet su slike ručno pisanih znamenaka dimenzije 28×28 , obojanih s 256 razina sive boje. One ulaze u prvi dvodimenzionalni konvolucijski sloj s 32 filtra dimenzije 3×3 i aktivacijskom funkcijom ReLU. Na to se slaže prvi sloj združivanja u dvije dimenzije. Koristi se način MaxPooling, s kvadratnom matricom 2×2 . To se ponavlja još jedanput, ovaj put sa 64 filtra. Poslije toga opet dolazi konvolucijski sloj sa 128 filtara, nakon čega se za potrebe potpuno povezane mreže s 10 neurona, za potrebe krajnje klasifikacije znamenaka koja dolazi na kraju, s aktivacijskom funkcijom softmax, trodimenzionalna struktura ($28 \times 28 \times 128$) „ravna“ (pretvara u jednodimenzionalni vektor). Zadnja naredba objedinjuje sve slojeve u jedinstvenu mrežu. Pregled modela opet daje naredba `model.summary()`.

```
>>> model.summary()
Model: "model"
```

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 28, 28, 1)]	0
conv2d (Conv2D)	(None, 26, 26, 32)	320
max_pooling2d (MaxPooling2D)	(None, 13, 13, 32)	0
conv2d_1 (Conv2D)	(None, 11, 11, 64)	18496
max_pooling2d_1 (MaxPooling2)	(None, 5, 5, 64)	0
conv2d_2 (Conv2D)	(None, 3, 3, 128)	73856
flatten (Flatten)	(None, 1152)	0
dense (Dense)	(None, 10)	11530

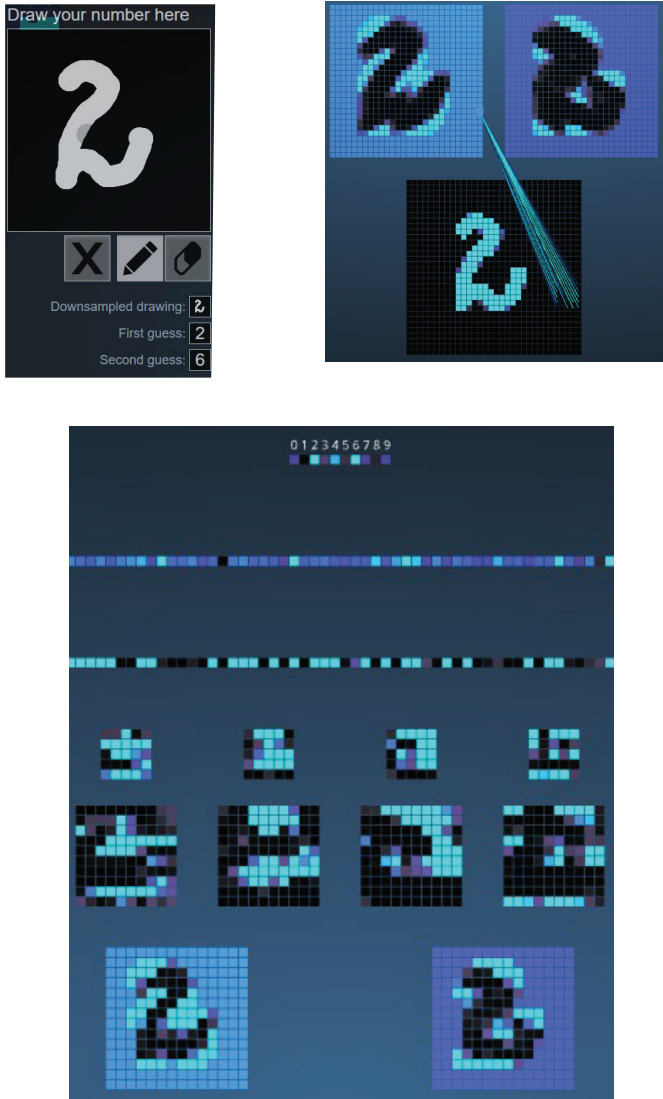
=====
Total params: 104,202
Trainable params: 104,202
Non-trainable params: 0
=====

Čitatelj će uočiti bitno manji broj parametara koje mreža mora naučiti u odnosu na višeslojni perceptron. Ostatak kôda gotovo je istovjetan kôdu višeslojnog perceptrona pa ga ovdje ne izlažemo. Testiranje mreže pokazuje učinkovitost od 99,1% (usporediti s višeslojnim perceptronom)

```
>>> test_loss, test_acc = model.evaluate(test_images, test_labels)
>>> print(f"Test accuracy: {test_acc:.3f}")
Test accuracy: 0.991
```

U nastavku prikazujemo isječke rada simulatora Adama Harleya (https://adamharley.com/nn_vis/cnn/2d.html) na primjeru raspoznavanja znamenaka dvodimenzionalnom konvolucijskom mrežom koje u sustav unosi korisnik sam. Na njima se, slijedom od vrha stranice prema dnu, vidi da je mreža valjano raspoznala upisanu znamenku (prvi izbor-najveća vjerojatnost), dok joj je drugi izbor bila znamenka 6. Zatim vidimo rezultate konvolucije dvaju

filtara nad digitaliziranim ulaznim zapisom. Donja slika prikazuje slijed mapa svojstava nakon uzastopnih konvolucija i združivanja, nakon čega slijedi „ravnanje“ i krajnja klasifikacija znamenke.



SLIKA 4-56: Simulator Adama Harleya na djelu.

Literatura

Abelson, H. and Disessa, A. (1986) *Turtle Geometry: The Computer as a Medium for Exploring Mathematics*. The MIT Press.

Alpaydin, E. (2021). *Strojno učenje*, MATE, Zagreb (prijevod na hrvatski jezik knjige Alpaydin, E. (2016) *Machine Learning* (The MIT Press Essential Knowledge series), The MIT Press, prevela Petra Rebernjak.

Argamon, S. (2007). Interpreting Burrows's Delta: Geometric and Probabilistic Foundations. *Literary and Linguistic Computing*, 23(2), 131–147. <https://doi.org/10.1093/lc/fqn003>.

Bast, H., Buchhold, B., Haussmann, E. (2016). *Semantic Search on Text and Knowledge Bases*. Now Publishers Inc.

Bettini, L. (2016) *Implementing Domain Specific Languages with Xtext and Xtend*. Packt Publishing.

Binongo, J. and Smith, M. (1999) "The application of principal component analysis to stylometry," *Literary and Linguistic Computing*, 14(4), pp. 445–466. Available at: <https://doi.org/10.1093/lc/14.4.445>.

Burrows, J. (2002). "Delta": a Measure of Stylistic Difference and a Guide to Likely Authorship. *Literary and Linguistic Computing*, 17(3), 267–287. <https://doi.org/10.1093/lc/17.3.267>.

Burrows, J. (2002B). The Englishing of Juvenal: computational stylistics and translated texts. *Style*, 36(4), 677. <https://www.jstor.org/stable/10.5325/style.364.677>.

Ceruzzi, P. E. (2022). *Računalstvo: kratka povijest*, MATE, Zagreb (prijevod na hrvatski jezik knjige Ceruzzi, P. E. (2022) *Computing: A Concise History* (The MIT Press Essential Knowledge series), The MIT Press, preveo M. Čubrilo.

Chollet, F. (2021). *Deep Learning with Python*, Second Edition, Manning.

Cortelazzo, M. A., Nadalutti, P. i Tuzzi, A. (2013). Improving Labbé's Intertextual Distance: Testing a Revised Version on a Large Corpus of Italian Literature. *Journal of Quantitative Linguistics*, 20(2), 125–152. <https://doi.org/10.1080/09296174.2013.773138>

Crochemore, M., Hancart, C. Lecroq, T. (2007). *Algorithms on Strings*. Cambridge University Press.

Crochemore, M., Rytter, W. (1994). *Text Algorithms*. Oxford University Press.

Cubrilo, M., Lovrencic, A., Malekovic, M. (2001). A HiLog Journey from a Classical Dictionary to Hypertext Structure (via the Grammar, of course). *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 5(5), 286–293., Fuji Press, <https://doi.org/10.20965/jaciii.2001.p0286>.

Cömert, C., Özbayoğlu, M., Kasnakoğlu, C. (2021). Painter Prediction from Artworks with Transfer Learning, *The 7th International Conference on Mechatronics and Robotics Engineering*, 204-208.

Čubrilo, M. (1989). *Matematička logika za ekspertne sisteme*, IBI-15, Informator Zagreb.

Delmonte, R. (2008). *Computational Linguistic Text Processing*. Nova Biomedical Books.

Denning, P. J., Tedre, M. (2021). *Računalno razmišljanje*, MATE, Zagreb (prijevod na hrvatski jezik knjige Denning, P. J., Tedre, M. (2019) *Computational Thinking*, The MIT Press Essential Knowledge series, The MIT Press, preveo M. Čubrilo.

Duboue, P. (2020). *The Art of Feature Engineering: Essentials for Machine Learning* (1st ed.). Cambridge University Press.

Elgammal, A., Kang, Y., Den Leeuw, M. (2018). Picasso, Matisse, or a Fake? Automated Analysis of Drawings at the Stroke Level for Attribution and Authentication. *Proceedings of the AAAI Conference on Artificial Intelligence*, 32(1). <https://doi.org/10.1609/aaai.v32i1.11313>.

Epstein, R., Roberts, G., Beber, G. (2008). Parsing the Turing Test: Philosophical and Methodological Issues, u *Quest for the Thinking Computer* (izd. 2009.). Springer.

Fagin, R., Halpern, J. Y., Moses, Y. (2004). *Reasoning About Knowledge*. MIT Press.

Farlow, S. J. (1981) The GMDH Algorithm of Ivakhnenko, *The American Statistician*, sv. 35, 1981, br. 4.

Fitzgerald, M. (2012). *Introducing Regular Expressions: Unraveling Regular Expressions, Step-by-Step* (1st ed.). O'Reilly Media.

Fraile-Narváez, M., Sagredo-Olivenza, I., McGowan, N. (2022). Painting Authorship and Forgery Detection Challenges with AI Image Generation Algorithms: Rembrandt and 17th Century Dutch Painters as a Case Study, *International Journal of Interactive Multimedia and Artificial Intelligence*, 7(7):7.

Frank, S. J. i Frank, A. M. (2021). A Neural Network Looks at Leonardo's(?) *Salvator Mundi*. *Leonardo*, 54(6), 619–624. https://doi.org/10.1162/leon_a_02004

Giansiracusa, N. (2021). *How Algorithms Create and Prevent Fake News: Exploring the Impacts of Social Media, Deepfakes, GPT-3, and More*, Apress.

Goyvaerts, J. (2006). *Regular Expressions: The Complete Tutorial*. Lulu.

GPT-3, Drozd, M. (2022). *The Curator: Future of Human-AI Interaction*.

GPT-3, Wurds, A. (2021). *The Real World; a Rules Lite Surrealist RPG*, Alley Faint Wurds Publisher.

Grieve, J. (2007). *Quantitative Authorship Attribution: An Evaluation of Techniques*. *Literary and Linguistic Computing*, 22(3), 251–270. <https://doi.org/10.1093/llc/fqm020>.

Groza, A. (2021) *Modelling Puzzles in First Order Logic*. Springer.

Hofstadter, D. R. (1999). *GÖDEL ESCHER BACH: Eternal golden braid*. Basic Books.

Hoover, D. L. (2004). Testing Burrows's Delta. *Literary and Linguistic Computing*, 19(4), 453–475. <https://doi.org/10.1093/llc/19.4.453>

Ivakhnenko, A.G. (1966). Group Method of Data Handling: A Rival of the Method of Stochastic Approximation, *Soviet Automatic Control*, 13, 43–71.

Kelleher, J. D. (2019). *Duboko učenje* (2021), MATE, Zagreb (prijevod na hrvatski jezik knjige Kelleher, J. D. (2019). *Data Science* (The MIT Press Essential Knowledge series), The MIT Press, preveo M. Čubrilo.

Kelleher, J. D., Tierney, B. (2021). *Znanost o podacima* (2018), MATE, Zagreb (prijevod na hrvatski jezik knjige Kelleher, J. D. (2019). *Deep Learning* (The MIT Press Essential Knowledge series) (Illustrated). The MIT Press, preveo M. Čubrilo.

Labbé, C. (2005). A Tool for Literary Studies: Intertextual Distance and Tree Classification. *Literary and Linguistic Computing*, 21(3), 311–326. <https://doi.org/10.1093/llc/fqio63>.

Labbé, D. (2007). Experiments on authorship attribution by intertextual distance in english*. *Journal of Quantitative Linguistics*, 14(1), 33–80. <https://doi.org/10.1080/09296170600850601>

Lagutina, K., Lagutina, N., Boychuk, E., Vorontsova, I., Shliakhtina, E., Belyaeva, O., Paramonov, I., Demidov, P. (2019). A Survey on Stylometric Text Features. 2019 25th Conference of Open Innovations Association (FRUCT). <https://doi.org/10.23919/fruct48121.2019.8981504>

Laramée, F. D. (2018). Introduction to stylometry with Python. *Programming*, <https://programminghistorian.org/en/lessons/introduction-to-stylometry-with-python>.

Madden, M. (2005). *99 Ways to Tell a Story: Exercises in Style* (1. izd.). Chamberlain Bros.

Maupassant, G. (1994) *BEL-AMI*, s francuskoga preveo Ivan Kušan, MOSTA, Zagreb.

Mayer, C., Riaz, Z., Rieger, L. (2020). *The Smartest Way to Learn Python Regex: Learn the Best-Kept Productivity Secret of Code Masters*. Independently published.

Mazur, M. (1970). *Jakościowa teoria informacji*. Wydawnictwo Naukowo-Techniczne, Warszaw.

Merriam, T. (2003). An Application of Authorship Attribution by *Inter-textual Distance in English. Corpus*, 2. <https://doi.org/10.4000/corpus.35>

Minsky, M. and Papert, S. (1988). *Perceptrons: An Introduction to computational geometry*. Expanded Edition, MIT Press.

Neal, T., Sundararajan, K., Fatima, A., Yan, Y., Xiang, Y., Woodard, D. (2018). Surveying Stylometry Techniques and Applications. *ACM Computing Surveys*, 50(6), 1–36. <https://doi.org/10.1145/3132039>.

Ording, P. (2021). *99 Variations on a Proof*. Princeton University Press.

Orešković, M. (2019). *An Online Syntactic and Semantic Framework for Lexical Relations Extraction Using Natural Language Deterministic Model*. Doctoral dissertation, FOI Varaždin, 2019.

Papert, S. (2020). *Mindstorms: Children, Computers, And Powerful Ideas. Revised*. Basic Books.

Pelletier, F.J. Automated Natural Deduction in Thinker. *Studia Logica* 60, 3–43 (1998)

Poundstone, W. (2006). *Fortune's Formula: The Untold Story of the Scientific Betting System That Beat the Casinos and Wall Street*, Hill and Wang.

Poundstone, W. (2011). *Labyrinths of Reason: Paradox, Puzzles, and the Frailty of Knowledge*. Van Haren Publishing.

Poundstone, W. (2013). *The Recursive Universe: Cosmic Complexity and the Limits of Scientific Knowledge*, Dover Publications.

Prusinkiewicz, P. i sur. (1996). *The Algorithmic Beauty of Plants (The Virtual Laboratory)*. First Edition. Springer.

Queneau, R. (2008). *Stilske vježbe*, s francuskoga preveo Vladimir Gerić, ŠARENI DUČAN, Koprivnica.

Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S.,

Sastry, G., Aspell, A., Mishkin, P., Clark, J., Krueger, G., Sutskever, I. (2021). Learning Transferable Visual Models From Natural Language Supervision. ArXiv: *Computer Vision and Pattern Recognition*. <http://export.arxiv.org/pdf/2103.00020>.

Raffaelli, I., Tadić, M., Bekavac, B., Agić, Ž. (2008). Building Croatian WordNet. *Fourth Global WordNet Conference (GWC 2008)*.

Renssen, V. A. (2015). *Semantic Information Modeling in Formalized Languages*. Lulu.

Rizvi, P. (2018). The interpretation of Zeta test results. *Digital Scholarship in the Humanities*, 34(2), 401–418. <https://doi.org/10.1093/llc/fqy038>.

Rizvi, P. (2018b). An improvement to Zeta. *Digital Scholarship in the Humanities*, 34(2), 419–422. <https://doi.org/10.1093/llc/fqy039>

Rizvi, P. (2022). The interpretation of zeta test results: a supplement. *Digital Scholarship in the Humanities*, 37(4), 1172–1178. <https://doi.org/10.1093/llc/fqac011>.

Savoy, J. (2020). *Machine Learning Methods for Stylometry: Authorship Attribution and Author Profiling*. Springer Publishing.

Schwarzentruber, F. (2018). Hintikka's World: Agents with Higher-order Knowledge. *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*. <https://doi.org/10.24963/ijcai.2018/862>.

Solanki, A., Nayyar, A., Naved, M. (2021). *Generative Adversarial Networks for Image-to-Image Translation* (1. izd.). Academic Press.

Tappert, C. C. (2019). Who Is the Father of Deep Learning? 2019 *International Conference on Computational Science and Computational Intelligence (CSCI)*. <https://doi.org/10.1109/csci49370.2019.00067>.

Verhoeff, T. T. (2010) "3D turtle geometry: artwork, theory, program equivalence and symmetry," *International Journal of Arts and Technology*, 3(2/3), p. 288.

Viprey, J. M., Ledoux, C. N. (2006). About Labbe's "intertextual distance." *Journal of Quantitative Linguistics*, 13(2–3), 265–283. <https://doi.org/10.1080/09296170600855444>

Berry, D. (2011). Computational turn: thinking about digital humanities. *Culture Machine*, sv. 12, dostupno na: <http://sro.sussex.ac.uk/id/eprint/49813>. Pristupljeno: 1. listopada 2022.

Berry, D. M. (2012). Understanding the Digital Humanities., U *Understanding Digital Humanities*. Ur. Berry, D. M., London and New York: Palgrave Macmillan, str. 1-21.

- Burdick, A. i sur. (2012). *Digital Humanities*. The MIT Press.
- Busa, R. (2008). Perspectives on the Digital Humanities. U: *A Companion to Digital Humanities*. Ur. Schreibman, S., Siemens, R., Unsworth, J. Oxford: Blackwell.
- Clement, T. (2016). Where is Methodology in Digital Humanities? U: *Debate in Digital Humanities*. Ur. Gold, M. G., Klein, F. L. Minneapolis: University of Minnesota Press.
- Gadamer, H. G. (1978). *Istina i metoda. Osnovi filozofske hermeneutike*. Veselin Masleša. Sarajevo.
- Gardiner, E., Musto, R. G. (2015). *The Digital Humanities*. New York: Cambridge University Press.
- Hayles, N. K. (2012). *How We Think*. Digital Media and Contemporary Technogenesis. Chicago and London: The University of Chicago Press.
- Hesure, R., Le-Khac, L. (2012). A Quantitative Literary History of 2,958 Nineteenth-Century British Novels: The Semantic Cohort Method. *Pamphlets of the Stanford Literary Lab*.
- Hockey, S. (2012). Digital Humanities in the Age of the Internet: Reaching Out to Other Communities. U: *Collaborative Research in the Digital Humanities*. Ur. Deegan, M., McCarty, W. England and USA: ASHGATE, str. 81-93.
- Hockey, S. (2005). The History of Humanities Computing. U: *A Companion to Digital Humanities*. Ur. Schreibman, S., Siemens, R. i Unsworth, J. Oxford: Blackwell.
- Ide, N. (1987). Computers and the Humanities Courses: Philosophical Bases and Approach. *Computers and the Humanities*. sv. 21, No. 4, str. 209-215.
- Karsdorp, F. Kestemont, M. i Riddell, A. (2021). *Humanities Data Analysis. Case Studies with Python*. Princeton and Oxford: Princeton University Press.
- Kirschenbaum, M. (2012). What is Digital Humanities and What's It Doing in English Departments? U: *Debates in the Digital Humanities*. Ur. Gold, M. K. Minneapolis and London: University of Minnesota Press.
- Kokić, T. (2013). Industrijalizacija sveučilišta i dehumanizacija. *Filozofska istraživanja*, sv. 33, br. 3, str. 425-432.
- Kuhn, T. (2013). *Struktura znanstvenih revolucija*. Zagreb: Naklada Jesenski i Turk.
- Liu, A. (2013). The Meaning of the Digital Humanities. *PMLA*, sv. 128, br. 2. Modern Language Association, str. 409-423.

Manovich, L. (2013) *Software Takes Command*. New York: Bloomsbury Academic.

Manovich, L. (2020). *Cultural Analytics*. Cambridge, London: The MIT Press.

McCarty, W. (2005). Modeling: A Study in Words and Meanings. U: *A Companion to Digital Humanities*. Ur. Schreibman, S., Siemens, R. i Unsworth, J. Oxford: Blackwell.

Mendelman, L., Mukamal, A. (2021). The Generative Dissensuns of Reading the Feminist Novel, 1995-2020: *A Computational Analysis of Interpretative Communities*. *Journal of Cultural Analytics*. Dostupno na: <https://doi.org/10.7910/DVN/4ATJCF>.

Moretti, F. (2013). *Distant Reading*. London and New York. Verso.

Nikolić, D. (2016). Digitalna humanistika i nacionalna filologija: o mogućim implikacijama računalnog obrata. *Croatica*, Br. 60, str. 75-87.

O'Donnell i sur. (2016). Only Connect: The Globalization of the Digital Humanities. U: *A New Companion to Digital Humanities*. Ur. Schreibman, S., Siemens, R. i Unsworth, R. Oxford: Blackwell.

Prescot, A. (2016). Beyond the Digital Humanities Center: The Administrative Landscape of the Digital Humanities. U: *A New Companion to Digital Humanities*. Ur. Schreibman, S., Siemens, R., Unsworth, R. Blackwell.

Raben, J. (1991). Humanities Computing 25 Years Later. *Computers and the Humanities*, sv. 25, br. 6, str. 341-350.

Dostupno na: <https://www.jstor.org/stable/30208117>.

Schnapp, J., Presner, T. (2009). The Digital Humanities Manifesto 2.0. Dostupno na: https://www.humanitiesblast.com/manifesto/Manifesto_v2.pdf. (Pristupljeno 2. rujna 2022.)

Svensson, P. (2012). Beyond the Big Tent. U: *Debates in the Digital Humanities*. Ur. Gold. M. K. Minneapolis: The University of Minnesota Press.

Svensson, P. (2010). The Landscape of Digital Humanities. *Digital Humanities Quarterly*. sv. 4, no. 1, str. 1-38.

Svensson, P. (2016). *Big Digital Humanities: Imagining Meeting Place for the Humanities and the Digital*. University of Michigan Press.

Tabak, E. (2017). *Digitalna humanistika: Debate, aplikacije, izazovi*. Zenica: Filozofski fakultet Univerziteta u Zenici.

Dostupno na: https://unze.ba/digitalna_humanistika/digitalna_humanistika.pdf.

Tadić, M. (2016). László je samo jedan. *Vijenac*. sv. 24, No. 571, str. 9.

Terras, M. (2013). Disciplined: Using Educational Studies to Analyse 'Humanities Computing'. U: *Defining Digital Humanities. A reader*. Ur. Terras, M., Nyhan, J. Vanhoutte, W. ASHGATE.

Vanhoutte, W. (2013). The Gates of Hell: History and Definition of Digital Humanities Computing. U: *Defining Digital Humanities. A reader*. Ur. Terras, M., Nyhan, J., Vanhoutte, W. ASHGATE.

Waltzer, L. (2016). Digital Humanities and the 'Ugly Stepchildren' of American Higher Education. U: *Debates in the Digital Humanities*. Ur. Gold. M. K. Minneapolis and London: University of Minnesota Press.

Warwick, C. (2016). Building Theories or Theories of Building? A Tension at the Heart of Digital Humanities. U: *A New Companion to Digital Humanities*. Ur. Schreibman, S., Siemens, R. i Unsworth, R. Oxford: Blackwell.

Wymer, K. C. (2021). *Introduction to Digital Humanities. Enhancing Scholarship with the Use of Technology*. New York and London: Routledge.

Zelenika, R. (2007). Klasifikacija znanosti u fokusu metodologije i tehnologije znanstvenog istraživanja. *Pomorski zbornik*. No. 44, str. 11-39.

Žugaj, M. (1989). Jedno predavanje o klasifikaciji znanosti. *Journal of Information and Organizational Sciences*. sv. No. 13, str. 257-276.

Kazalo pojmov

A

aksiom

negativne introspekcije 137

pozitivne introspekcije 137

aksiomi znanja 137

akson 265, 266

aktivacijska funkcija 267, 269, 273

softmax 269, 273, 284

ALLC Bulletin 31

Anaconda

razvojno p rogramsko okruŹje 179, 203, 263, 271, 272

analiza glavnih komponenata *viii*, 142

analiza teksta 140

Apple Macintosh 24, 27

arheologiji znanja 57

arhitektura

umjetne neuronske mreŹe 263

perceptrona 264

Association for Computational Linguistic 24

Automatic Digital Calculators 18

B

Basic 197, 289, 290

baz znamenaka MNIST 271

Bezierove krivulje 173

biblioteka Pandas 78, 139, 263

bioloŹki neuron 265

Bonan Zhao 131

Burrowsov model Delta 142

Burrowsov test Zeta *viii*, 142, 155

buŹene kartice 16, 19, 22

C

Centar za razvoj digitalnih kompetencija i tehnologija e-učenja ix, 72
centerNet 66
CHANSE 68
ChatGPT *xiv*, 172, 184, 190, 245, 246, 248, 249, 251, 252, 259, 260, 261, 262
Computers for the Humanities? 30

D

DALL•E 170, 171, 172, 262
Danica Ilirska 135
DARIAH 66, 68
David Hilbert 194
dendriti 265, 266
Dialect Atlas of South-West Germany 25
Digital Humanities Quarterly 65
digitalizacija x
digitalna humanistika *vii*, *x*, *xii*, 2, 10, 11, 12, 13, 14, 15, 38, 40, 42, 50, 52, 54, 55, 63
duboko učenje *xiii*, 121, 141, 263, 264
duhovne znanosti 6
DynaText SGML 28

E

e-book uređaji 49
eliptička geometrija 197
Euklid 195

F

filolozi
 Erich Auerbach 8
 Leo Spitzer 8
 René Wellek 8
formalne gramatike *viii*, 175
Francoise Viette 113
funkcija troška 269

G

geometrija

 kornjače 176

 Lobačevskoga 196

GitMind, 128

Google Books 49

Guidelines for Electronic Text Encoding and Interchange 24

Guidelines for the Encoding and Interchange of Machine Readable Texts 24

H

Hilog. 189

hiperbolička geometrija. *Vidi također* geometrija Lobačevskog

hiperbolički tetris 198

hipertekst 47

humanistička informatika 10, 13

humanističke znanosti *x*, 4, 8, 10, 13, 14, 26, 39, 60, 120

humanističko računalstvo vii, 2, 10, 15, 30, 33, 36, 37, 38

Humanistika

 1.0

x, 4, 8, 10, 13, 14, 26, 39, 60, 120

 2.0

x, 4, 8, 10, 13, 14, 26, 39, 60, 120

Humboldtova ideja sveučilišta 3

Hyper-card

 Appleovo računalo 27

HyperText Markup Language (HTML) 28

I

IBM 22, 30, 32, 130

Index Thomisticus 22

International Conference on Computer in the Humanities 31

International Linguistic Congress 18

inženjerstvo svojstava 279

Ivanenkova metoda 265

J

Jensen Huang 109
Jupyter
 modul sustava Anaconda 179, 203, 263, 271, 272

K

Kaibo Xie 130
Keras
 programaska biblioteka, modul sustava TensorFlow 284
koeficijent korelacije 143
konjunkt 226
konjunktivna primitivna normalna forma suda 226
konvolucija 278, 279
konvolucijska neuronska mreža viii, 263, 275, 277, 279, 281, 283
konvolucijski filtar 277
kulturna analitika 10, 83, 88

L

Labbéovska međutekstovna udaljenost viii, 142, 164
Literary and Linguistic Computing 30- 32, 42, 287, 289
logička dedukcija 200
logička funkcija
 ekskluzivno „ili“ 264
logička argumentacija 123
LOGO 176
L-sustavi 178, 180

M

matrica kovarijanci 146
Matrica kovarijanci 144, 145, 146, 147, 151, 163
Mechanical Translation
 časopis 18
Mentalna mapa viii, 124, 128
metaznakovi 186
metoda gradijentnog spusta 269

MicroOCP 24
MindManager 124, 128
MindMeister 124, 128
MindMeister, 124, 128

N

nadgledano učenje 269
NeDiMAH 68
neeuclidiske geometrije 195
nelinearna aktivacijska funkcija 266
 sigmoidna 267
 po dijelovima linearna 267
 tangens hiperbolni 267
neuron
 prvi skriveni sloj 268
neuronska mreža *xiii*, 104, 141, 169, 170, 263, 264, 265, 266, 267, 271, 275, 278, 280, 284
 konvolucijska *viii*, *xiv*, 170, 263, 264, 265, 267, 269, 270, 272, 275, 276, 277, 278, 281, 283
 potpuno povezana 268
neuronske mreže *viii*, *xiv*, 170, 263, 264, 265, 267, 269, 270, 272, 275, 276, 277, 278, 281, 283
 stopa učenja 270
N-gram 139
Nita Engle
 slikarica 280
normalizacija podataka 144
normalizirana slučajna varijabla 144
NVIDIA 109, 110

O

obrat po kontrapoziciji 122, 212
Obrat po kontrapoziciji 122
ontologije Gellish 137
OpenAI 170, 172, 261, 262
OpenText SGM 28

osjetilna inteligencija 109

Oxford Text Archive 26

P

Pascal 35

pogreška klasifikacije 269

pojam interpretacije suda 224

Poughkeepsie Principles 23

pravilo rezolucije za račun sudova 224

pristranost 267

Problem

analize sentimenta 141

atribucije autorstva teksta 140, 141

profiliranja autora 141

verifikacije 141

utvrđivanja plagijata 141

utvrđivanja lažnih vijesti 141

zajedničkog autorstva 141

vuka, koze i kupusa 240

program

History and Computing 36

Humanities Computing 33, 36, 37, 42, 43, 292, 293, 294

Prolog 35

prosljeđivanja pogreške unatrag 269, 270

R

računalni vid 276

račun predikata prvog reda 200

Raymonda Queneaua

Stilske vježbe 133

Regex 101 184

RegexBuddy 184

regularni izrazi 139

rezoniranje o znanju 111

rudarenje teksta 50

S

Samoreferentni kvizovi 234
SAT-solver 234
Schurova dekompozicija 145
semantička tablica 220, 223, 267
SNOBOL 35
Standard Generalized Markup Language 24, 29
stilistička analiza 22
stilkronometrija 141
stilometrija 133
stilometrijska istraživanja 141

T

tablica istinitosti 267
TaDiRAH 28
Taxonomy of Digital Research Activities in the Humanities) 60
tehnocentrizam 28
tehnologije 28
tehnološka minijaturizacija 16
TEI 28
TensorFlow 263, 271, 278, 284
The Digital Humanities Manifesto 14, 293
The European Union's Digital Research Infrastructure for Arts and Humanities
initiative 28, 60
Thesaurus Linguae Graecae 28
Turingov test 136
Twitter 28

U

Umijeće ratovanja
Sun Tzu 124, 128, 132
umjetni neuron 268
umjetn inteligencija 109
Unicode 28
univerzalni Turingov stroj 200

V

van Emde Boas

Ghica 130

Peter 130

Vector Space Model 77

videokonferencijski sustav 111

višeagentni sustavi 111, 112, 137, 138

višeslojni perceptron viii, 263, 264, 268, 269, 271, 285

W

WAM. *See* Warren Abstract Machine

Warren Abstract Machine 200

Web 1.0 28

Web 2.0 28

Windows 28

Word Cruncher 28

World Wide Web 28

WYSIWYG

alat 28

X

XMind 124, 128

XML izraz

alat 28

Z

zdravorazumsko znanje 112

Zeta-vrijednosti 157

O autorima

Iva Rosanda Žigo

Rođena je 1978. godine u Rijeci. Diplomirala je Hrvatski jezik i književnost na Filozofskom fakultetu Sveučilišta u Rijeci, a doktorat znanosti stekla je na Filozofskom fakultetu Sveučilišta u Zagrebu. Akademsku karijeru započela je kao asistentica na Filozofskom fakultetu Sveučilišta u Rijeci, a na istom je Sveučilištu bila i predstojnica Centra za elektroničko nakladništvo. Godine 2015. prelazi na Sveučilište Sjever na kojem, danas kao izvanredna profesorica, drži kolegije iz područja novinarstva, izvedbeno-scenske komunikacije, teorije medija, teorije kulture i semiotike. Autorica je triju knjiga i više znanstvenih i stručnih radova objavljenih u međunarodnim časopisima, te zbornicima radova s međunarodnih znanstvenih konferencija. Pročelnica je Odsjeka za medije i komunikaciju te voditeljica Poslijediplomskog sveučilišnog doktorskog studija Mediji i komunikacija na Sveučilištu Sjever.

Nikolaj Lazić

Rođen je 1973. godine u Zagrebu. Doktorirao je u polju Informatičkih i komunikacijskih znanosti s temom naslova Modeliranje strojnih postupaka za izgovaranje teksta pisanoga hrvatskim jezikom. Akademsku karijeru započeo je na Filozofskom fakultetu kao asistent, znanstveni novak na projektu profesora emeritusa Ive Škarića. Tema koju otvara kroz doktorski rad ostaje mu i dalje u interesu. U znanstvenom i nastavnom radu usmjeren je na problematiku informatijske tehnologije, sinteze govora, računalne tehnologije u obradi prirodnog jezika, informatijskih sustava, te informatijske tehnologije i njenih mogućnosti u obrazovanju i AKM institucijama. Redoviti je profesor, autor je više znanstvenih i stručnih radova objavljenih u međunarodnim časopisima i zbornicima radova s međunarodnih znanstvenih konferencija.

Mirko Čubrilo

Rođen je 1953. godine u Josipovcu kod Osijeka. Završio je studij teorijske matematike na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu te znanstveni magistarski studij matematike na istom fakultetu, sa specijalizacijom u području matematičke logike. Doktorirao je na Elektrotehničkom fakultetu Sveučilišta u Zagrebu na temu Ijuski ekspertnih sistema s deduktivnim mehanizmom tipa sistema produkcija.

Bavi se teorijom algoritama i simboličom logikom, s naglaskom na primjene u domeni struktura podataka, baza podataka, logičkog programiranja i umjetne inteligencije.

Na više visokoškolskih institucija Republike Hrvatske predavao je ukupno više od dvadeset kolegija, uključujući *Teoriju klasifikacije*, *Strukture podataka*, *Baze podataka*, *Logičko programiranje*, *Formalne metode za informacijske tehnologije*, *Odabrana poglavlja umjetne inteligencije*, *Odabrana poglavlja logike konflikta*, itd.

Autor je više od pedeset radova, objavljenih na međunarodnim znanstvenim konferencijama i znanstvenim časopisima, te autor jedne, koautor još jedne knjige te niza poglavlja u više knjiga.

S engleskoga na hrvatski jezik preveo je petnaest knjiga iz područja poslovanja, informatike, matematike i statistike.

Od 2009. godine redoviti je profesor u trajnom zvanju Sveučilišta u Zagrebu. Trenutačno djeluje na Sveučilištu Sjever.

Ova knjiga uvodi nas, kroz povijesni prikaz razvoja i uporabe računalnih tehnologija, u promjene koje je računalna tehnologija potaknula u humanističkom području. Kroz pregled razvoja, projekata i konferencija pokazuje nam, kako je, ono što je u početku bila „utopija“ i samotnjački rad entuzijasta, postalo i postaje alat humanista.

Stoga ću reći da mi je čitanje ove knjige probudilo sjećanja na početke rada u području humanističkog računarstva, podsjetilo me na projekte koji su u vrijeme prijave imali predznak „utopijski“. Drago mi je da knjigu mogu preporučiti, posebno studentima i doktorandima, kao mladoj znanstveno istraživačkoj snazi. Knjiga, osim odličnog pregleda razvoja područja digitalne humanistike otvara i pitanja obrazovanja u tom području i daje viziju u kom pravcu idu novi projekti i mogućnosti informacijsko komunikacijske tehnologije.

Autori knjige poznati su znanstvenici područja o kojemu pišu kao teoretičari i praktičari pa će tim više imati primjenu kao literatura studentima i doktorandima, ali i kao izvor ideja za daljnja istraživanja.

Prof.dr.sc. Damir Boras

Knjiga, kroz svoj sadržaj daje odličan pregled razvoja u polju humanističkog računarstva, koje ima dugu i dinamičnu povijest koju su autori uspjeli predstaviti kao cjelinu. Predstavili su područje kroz različite discipline koje se isprepliću s primjerima iz prakse i rješenjima koja su u određeno vrijeme tehnološkog razvoja i primjene tražila suradnju, do tada nespojivih disciplina i područja. Tako se sadržaj kreće od onog povijesnog i trenutnog do onog što otkriva pogled u budućnost. Vidljivo je da su autori knjizi namijenili, s jedne strane, povijesni zapis o tom području, dodirujući sadašnji trenutak s pogledom na situaciju u svom okruženju, a s druge strane, dali su nam pogled u budućnost koja je u svakom trenutku, s obzirom na razvoj alata i metoda, gotovo pa sadašnjost. Ono što je nekako zajedničko, prošlosti, sadašnjosti i budućnosti i provlači se kroz sadržaj, je pitanje obrazovanja koje leži u središtu budućnosti digitalnih humanističkih znanosti.

Unatoč tome, što različite discipline koje čine humanističke znanosti, barataju s različitim artefaktima koji nose znanje, kojima su humanisti godinama pristupali na svoj jedinstven način, sada, kako nam to autori govore i pokazuju, kroz interdisciplinarni pristup, dosljednošću koju zahtijeva računalno okruženje počinju koristiti nove metode, pokazujući da razumiju načine na koje taj predmet premašuje ili izmiče predstavljanju na klasičan način. Ono što nam autori dalje poručuju je, da danas, u računalno potpomognutoj analizi velikih količina digitalnog materijala koji je kodiran i obrađen u dobro promišljenom sustavu predstavljanja znanja, imamo priliku za opažanje i analiziranje obrazaca, spojeva i veza samo se moramo otvoriti za računalno promišljanje i prisvajanje novih metoda koje do sada u području humanistike nismo koristili i nismo smatrali svojim. Knjiga isto tako potiče studente i znanstvenike na daljnje propitivanje dobivenih rezultata, ali i na nove korake, jer je puna ideja koje traže rješenja.

Prof. dr. sc. Senada Dizdar