

MIRJANA MATEA KOVAČ

University of Split
Faculty of Electrical Engineering,
Mechanical Engineering and Naval Architecture

Utjecaj kognitivne složenosti zadatka na samoispravljanja

Ključne riječi: govorne pogreške, monitoring, samoispravljanje pogreška, kognitivna kompleksnost zadatka

1. Uvod

Procesi jezične obrade, razumijevanje govora i govorna proizvodnja mogu se s psiholingvističkog stajališta promatrati kao procesi organizacije jezičnih izričaja s jedne strane i unutrašnje, mentalne reprezentacije s druge strane. Izvedba govornog čina uključuje više od prijenosa informacije sugovorniku, ona uključuje i komunikacijsku namjeru koju sugovornik treba prepoznati i pravilno protumačiti. Levelt (1989) objašnjava proces proizvodnje govora koji polazi od planiranja sadržaja do artikulacijske realizacije. Ukupni proces je međudjelovanje nekoliko sastavnica: konceptualizatora, od kojeg polazi planiranje sadržaja i stvaranje predjezičnih konceptualnih struktura, formulatora, sastavnice koja oblikuje morfosintaktički sadržaj, te artikulatora koji prevodi jezični program u artikulacijski izlaz. On razlikuje makroplaniranje u kojem se kompleksni ciljevi razlažu u manje podciljeve, dobivaju strukturu i izražavaju govornim činovima. Pojedinačni govorni činovi se u okviru mikroplaniranja inkrementalno dalje obrađuju u predjezične konceptualne strukture i prosljeđuju formulatoru na daljnju obradu. Mikroplaniranje finalizira

govorni čin i poruci daje obavijesnu strukturu, koja će sugovorniku omogućiti razumijevanje komunikacijske namjere. Unatoč automatiziranoj prirodi proizvodnje materinskog jezika, govornici ne proizvode savršen govor, nego griješe, ponavljaju dijelove izričaja, koriste poštapalice i druge govorne disfluentnosti. Ipak, govornik većinu svojih pogrešaka ispravlja bez intervencije sugovornika, što ukazuje na postojanje kontrolnog mehanizma koji nadgledava točnost i prikladnost izričaja. Distribucije samoispravljanja te omjeri samoispravljanja i pogrešaka pružaju indirektnu informaciju o funkcioniranju i osjetljivosti tog mehanizma na različite kategorije pogrešaka i govorne neprikladnosti. Istraživanja u ovom području potvrđuju da je monitor posebno osjetljiv na leksičke pogreške (npr. Bredart 1991, Levelt 1983, van Hest 1996). Takav zaključak nije iznenađujući, budući da pogrešno odabrana riječ može izmijeniti obavijesni sadržaj poruke i ugroziti razumijevanje komunikacijske namjere. Rezultati također ukazuju da je učestalost samoispravljanja nedovoljno preciznog ili neprikladnog izričaja uvjetovana specifičnom prirodom zadatka i situacijskim varijablama interakcije (van Hest 1996). Odabrani zadaci u dosadašnjim istraživanjima uglavnom uključuju opisivanje statičnih objekata i konstelacija, posebno prostornih odnosa (npr.: gore-dolje, lijevo-desno). Posebna pozornost posvećuje se procesima linearizacije makrorazine, odnosno načinu na koji se višedimenzionalne sadržajne reprezentacije prevode u linearne jezične strukture. Levelt (1989: 138) ovaj problem konceptualizacije objašnjava na sljedeći način “deciding what to say first, what to say next, and so on...”. Kod opisivanja prostornih odnosa Levelt (1989) zaključuje da ispitanici slijede tri principa: princip povezivanja, princip „stoga” te princip minimalnog napora. Povezivanje je opći princip organizacije elemenata u percepciji i pamćenju, a princip „stoga” dominantan je način nadgledavanja hijerarhijski organizirane strukture. Princip minimalnog opterećenja nalaže da se informacija organizira tako da memorijski napor bude minimalan, što znači da govornici najprije opisuju manje zahtjevne konstelacije. Ovi principi podređeni su principu prirodnog poretka. Kod prepričavanja nekog događaja prirodni poredak je kronološki poredak događaja (Levelt 1989). Međutim, princip prirodnog poretka je teško primijeniti u domeni opisivanja dinamičnih konstelacija, a razlozi se mogu pronaći u dinamičnim aspektima događaja, za razliku od statičnih objekata i konstelacija. Kada je informacija koju treba prenijeti kompleksna i ako uključuje nekoliko uzastopnih govornih činova, tada govornik mora odlučiti na koji način će or-

ganizirati informacije. To je govornikov problem linearizacije (Levelt 1989), a princip prirodno redosljeda nalaže da se u vremenskoj domeni govorni čini izrazi kronološkim redosljedom. Istraživanja koja se temelje na zadacima opisivanja prostornih konstelacija (Levelt 1982) imaju za cilj utvrditi kako se statična prostorna struktura koristi za konstrukciju linearnog poretka koji se prilikom izgovora vremenski realizira. Kod opisivanja objekata i konstelacija riječ je o statičnim entitetima (Verhoeven 1989, Levelt 1983), dok je kod opisivanja događaja riječ o prostorno-vremenskim entitetima (Van Hest 1996, Lennon 1990, Wiese 1982, Fathman 1980).

U ovom radu istražuje se kako kognitivna složenost specifičnog tipa govornog zadatka utječe na samoispravljanja određene kategorije. Polazište za identifikaciju samoispravljanja pogrešaka i neprikladnosti kod analize zvučnog zapisa je Leveltova (1983, 1989) klasifikacija samoispravljanja. Iznose se rezultati dosadašnjih istraživanja o distribucijama samoispravljanja koja pružaju indirektnu informaciju o funkcioniranju govornog kontrolnog mehanizma. Slijede cilj i metodološki postupci istraživanja te zaključci dobiveni analizom govornog uzorka ispitanika tehničkih studija.

2. Leveltova klasifikacija samoispravljanja

Levelt (1983) je prvi psiholingvist koji je predložio preciznu klasifikaciju samoispravljanja koja se temelji na njegovom modelu govorne proizvodnje, a prihvaćen je kao empirijski najbolje potvrđeni model za monolingvalno procesiranje govora (npr. Kormos 2006). On razlikuje sljedeće kategorije:

1. *D-repair* – ispravak različitom informacijom (engl. *Different information repair*) kojim se mijenja sadržaj prvobitne obavijesti. Razlozi koji dovode do ispravljanja pripisuju se konceptualizatoru koji nije ispravno poredao ili je kodirao pogrešnu informaciju, što u oba slučaja rezultira neadekvatnim predverbalnim planom. Unutar ove kategorije, Levelt (1983) razlikuje sljedeće potkategorije:
 - a) Ispravak neprikladne ili pogrešne informacije (engl. *Inappropriate information repair*), kada se govornik ispravlja zato što je obavijesni sadržaj iskaza pogrešan;
 - b) Ispravak reorganizacijom elemenata unutar izričaja (engl. *Ordering error repair*), kada govornik odlučuje kodirati dijelove namjeravane poruke drugačijim redosljedom.

Ovakva samoispravljanja otkrivaju do koje mjere je sustav za proizvodnju govora usredotočen na prošlost, sadašnjost i budućnost, te pružaju informaciju o tome kako sustav rješava problem nizanja sastavnica. Teorija nizanja sastavnica u govoru mora zadovoljiti niz funkcionalnih zahtjeva: sustav treba aktivirati sadašnjost, deaktivirati prošlost i pripremiti aktiviranje budućnosti (Dell i sur. 1997). Govornik mora odlučiti kojim će redoslijedom poredati sastavnice ako želi izraziti kompleksniju informaciju. On može shvatiti da bi drugačiji raspored sastavnica bio možda prihvatljiviji, te odlučuje kodirati dijelove namjeravane poruke drugačijim redoslijedom (Levelt 1983). Levelt (1989) problem konceptualizacije objašnjava na sljedeći način: “Deciding what to say first, what to say next, and so on...” (Levelt 1983: 138). Pogreške uključuju anticipacije, kada se glasnici ili riječi izgovaraju prije vremena, ili perserveracije, kada se glasnici ili riječi izgovaraju naknadno.

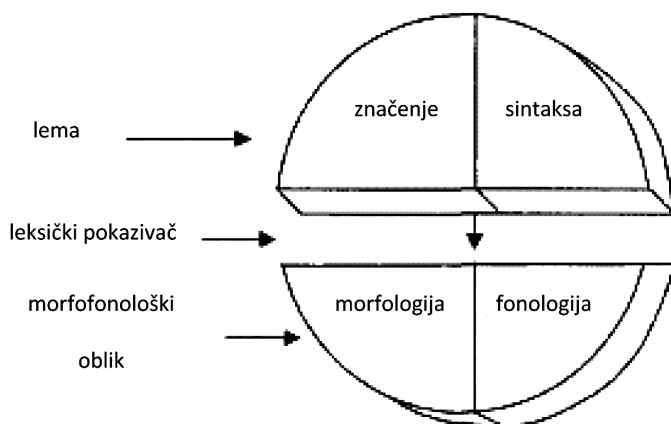
- c) Ispravak odbacivanjem poruke (engl. *Message abandonment repair*), kada govornik odustaje od namjeravane poruke i zamjenjuje je porukom drugačijeg sadržaja.
2. *A-repair* – ispravak neprikladna izričaja (engl. *Appropriacy repair*) je druga kategorija samoispravljanja kojoj je cilj specificirati obavijesni sadržaj poruke, odnosno ispravak nije posljedica pogreške. Levelt (1983) razlikuje tri potkategorije:
- a) Ispravak potencijalno dvosmislenog izričaja ili dijela izričaja (engl. *Ambiguity repair*);
 - b) Ispravak nedovoljno preciznog izričaja kojemu je potrebno dodatno pojašnjenje (engl. *Appropriate level of information*);
 - c) Ispravak izričaja koji nije koherentan s prije korištenom terminologijom (engl. *Coherence repair*).

Bredart (1991) je nadopunio Leveltovu klasifikaciju i uveo samoispravljanja kojima je cilj ispravljanje pragmatičke pogreške (engl. *Pragmatic appropriacy repair*). U ovom slučaju govornik ispravlja dijelove izričaja koji su pragmatički neprikladni u određenoj situaciji. Također, prema Bredartu (1991), govornik može ispraviti dio izričaja koji je pragmatički prihvatljiv, ali ga ne smatra dovoljno sofisticiranim (engl. *Repairs for good language*).

3. *E-repair* – ispravljanje pogrešaka (engl. *Error repairs*). Pogreške su rezultat neidealnog funkcioniranja na razini formulatora gdje se izabire pogrešno aktivirana riječ, neprikladna sintaktička konstrukcija, pogrešan morfem ili fonem. Prema ovome, Levelt (1983) razlikuje leksičke, sintaktičke i fonološke pogreške koje odgovaraju trima osnovnim razinama procesiranja. Prva faza u procesiranju predverbalnog plana je prizivanje konceptu odgovarajuće leme, pri čemu je koncept specificiran predverbalnim planom. Ispravak pogrešno aktivirane leme naziva se ispravkom leksičke pogreške (engl. *Lexical error repair*) (Levelt 1983, 1989). U Leveltovoј teoriji (1989) se sadržajne i funkcionalne riječi, te kolokacije i idiomi, smatraju leksičkim ulazima (engl. *Lexical entries*), slika 1. Leksički ispravak uključuje ispravak pogrešno aktiviranih sadržajnih i pojedinih funkcionalnih riječi, idioma i kolokacija. Ispravci derivacijske morfologije, npr. *different* umjesto *difference*, također pripadaju kategoriji samoispravljanja leksičkih pogrešaka, budući da u Leveltovu (1989) modelu leksikona derivacije čine različite leksičke ulaze¹.

Leksičke pogreške su definirane kao “any lexical item, colour words, direction terms, prepositions, articles, etc” (Levelt 1989: 54). Levelt (1989) pretpostavlja da je u slučaju leksičke pogreške aktiviran pogrešan leksički ulaz, i potom artikuliran. Samoispravljanja sintaktičkih pogrešaka uključuju ispravak sintaktičke konstrukcije koja vodi do „mrtve točke” i koju govornik ne može nastaviti (Levelt 1983: 54). Na žalost, Levelt nije dao definiciju fonetskih samoispravljanja, te ne objašnjava kamo se svrstavaju morfološke pogreške.

¹ Levelt (1989) pretpostavlja da svi oblici određene riječi imaju svoju vlastitu, odvojenu reprezentaciju u leksikonu, iako su srodni oblici riječi sadržani unutar jednog leksičkog ulaza. Leksički unos čini lema koja određuje značenje i sintaksu leksičkoga unosa, te leksem koji nosi informaciju o morfofonološkom obliku leksičkog unosa. Leksički pokazivač je mehanizam koji omogućuje povezivanje semantičke i fonološke razine u mentalnom leksikonu (Erdeljac 2009).



Slika 1: Prikaz leksičkog ulaza (Levelt 1989)

Horga (1997) razlikuje pogreške kongruencije, pogreške u otkrivanju izgovornog programa, izbor pogrešne riječi, te sintaktičko-propozicijske pogreške. Također, razlikuje i kategorije samoispravljanja koje se u većoj ili manjoj mjeri preklapaju s Leveltovom klasifikacijom: ubacivanje zaboravljenog podatka u izričaj, anticipacijsko srljanje, traženje novog podatka, te odbacivanje suvišnih elemenata u izričaju.

U tablici 1 prikazana je Leveltova taksonomija s pripadajućim primjerima, a nadopunjena je Bredartovim (1991) sustavom klasifikacije.

Tablica 1: Taksonomija samoispravljanja u materinskom jeziku

Vrsta ispravka	Primjer
<p>Ispravak različitom informacijom (engl. <i>Different information repair</i>)</p>	<p><i>We gaan rechtdoor offe...We komen binnen via rood, gaan dan.</i> <i>We go straight on or... We come in via red, go then straight to green.</i> (Levelt 1983: 51)</p>
<p>Ispravci neprikladnog izričaja (engl. <i>Appropriacy repairs</i>)</p> <p>Ispravak dvosmislenog izričaja (engl. <i>Ambiguity repairs</i>)</p> <p>Ispravak kojim se precizira izričaj (engl. <i>Appropriate level of information repairs</i>)</p> <p>Ispravak koherentnosti (engl. <i>Coherence repairs</i>)</p> <p>Ispravak „lošeg” jezika (engl. <i>Repair for good language</i>)</p>	<p><i>We beginnen in het midden met... in het midden van het papier met een blauw rondje.</i> <i>We start in the middle with... in the middle of the paper with a blue disc.</i> (Levelt 1983: 52)</p> <p><i>Met een blauw vlakje, een blauw aan de blovenkant</i> <i>With a blue spot, a blue disc at the upperend.</i> (Levelt 1983: 53)</p> <p><i>Ga je een naar boven, is uh... kom je bij geel.</i> <i>Go you one up, is uh... come you to yellow.</i> (Levelt 18983: 53)</p> <p><i>C'est qu'un con, un idiot pardon.</i> <i>He is nothing but a damn fool, an idiot sorry.</i> (Bredart 1991:127)</p>
<p>Ispravci pogrešaka (engl. <i>Error repairs</i>)</p> <p>Ispravak leksičke pogreške (engl. <i>lexical repair</i>)</p> <p>Ispravak sintaktičke pogreške (engl. <i>syntactic repair</i>)</p> <p>Ispravak fonološke pogreške (engl. <i>phonological repairs</i>)</p>	<p><i>Rechtdoor rood, of sorry, rechtdoor zwart</i> <i>Straight on red, or sorry, straight on black.</i> (Levelt 1983:53)</p> <p><i>En zwart...van zwart naar rechts naar rood.</i> <i>And black... from black to right to red.</i> (Levelt 1983:54)</p> <p><i>Een eenheid, eenheid vanuit de gele stip.</i> <i>A unut, unit from the yellow dot.</i> (Levelt 1983: 54)</p>

3. Distribucije samoispravljanja u dosadašnjim istraživanjima

Distribucije samoispravljanja su od velike važnosti u polju psiholingvističke zato što pružaju indirektnu informaciju o osjetljivosti sustava za nadgledavanje govora na različite kategorije pogrešaka i neprikladnosti. Kada se promatra kvantitativna distribucija različitih kategorija samoispravljanja, može se primijetiti da se u Leveltovu (1983) korpusu 42% samoispravljanja odnosi na ispravljanje pogrešaka, pri čemu su leksička samoispravljanja najučestalija kategorija samoispravljanja pogrešaka. Ispravak neprikladnog izričaja čini 30% od ukupnog broja samoispravljanja, prikriveni² ispravci obuhvaćaju 25%, a ispravak različitom informacijom je vrlo rijedak (1%). Levelt 3% pogrešaka nije mogao nedvojbeno svrstati u jednu od navedenih kategorija te ih stavlja u kategoriju „ostalo” (engl. *Rest*).

Za razliku od Leveltova istraživanja u kojemu su ispitanici opisivali prostorne konstelacije i gdje je govor auditivno sniman, Bredartov (1991) korpus čine direktno transkribirana, ali ne i snimljena samoispravljanja, najčešće televizijskih programa. Iako je Bredart (1991) koristio različitu metodu istraživanja i imao drugačiji korpus, uočena je određena sličnost u distribuciji samoispravljanja. Najčešća su ispravljanja pogrešaka (48%), prikriveni ispravci iznose 42% od ukupnog broja samoispravljanja, 7% su ispravci neprikladnog izričaja, ispravci različitom informacijom obuhvaćaju tek 1% samoispravljanja, a 3% otpada na kategoriju „ostalo”. Osnovna razlika se očituje u učestalostima samoispravljanja neprikladnog izričaja, što je najvjerojatnije posljedica zahtjeva za većom preciznošću izričaja kojeg nameće Leveltov tip zadatka. U Leveltovu (1983, 1989) istraživanju sudjelovala su 53 ispitanika kojima je nizozemski materinski jezik, a opisivali su uzorke na kojima su prikazani kružići različitih boja povezani strelicama, tako da je sugovornik iz govornikovog opisa mogao rekonstruirati izgled crteža. Levelt je ukupno zabilježio 959 samoispravljanja.

Van Hest (1996) je istraživala osobitosti samoispravljanja u materinskom (nizozemskom) i stranom (engleskom) jeziku na uzorku od 30 ispitanika. Prvi

² Prikrivena samoispravljanja odvijaju se na isti način kao i otkrivena. S obzirom da ispravak nije artikuliran, prisutnost indirektnih manifestacija poput ponavljanja riječi ili fraze, zamuckivanja, produžavanja glasnika, tihe i zvučne stanke, upućuju na postojanje takva procesa (Postma, Kolk 1992).

zadatak se odnosio na prepričavanje sadržaja radnje priče na temelju crteža, a u drugom zadatku su ispitanici imali intervju s izvornim govornikom nizozemskog, a potom engleskog jezika. Ukupno je zabilježeno 2079 samoispravljanja u nizozemskom jeziku. Distribucija samoispravljanja u nizozemskom razlikuje se od Levelta (1989) i od Bredarta (1996). Govornici u istraživanju Van Hest naprave u relativnim iznosima osjetno manje samoispravljanja pogrešaka nego Leveltovi (1989) i Bredartovi (1991) ispitanici (12%), te više samoispravljanja neprikladnog izričaja (47%) i samoispravljanja različitom informacijom (20%), što Van Hest objašnjava različitom prirodom zadataka.

Dosadašnja istraživanja su se uglavnom bavila utvrđivanjem distribucija samoispravljanja bez ispitivanja omjera samoispravljanja i pogrešaka (Kormos 2000). Jedno od malobrojnih istraživanja koje je proučavalo omjer samoispravljanja i pogrešaka u materinskom (nizozemskom) jeziku provela je Poulisse (1993). Njezini rezultati ukazuju da se leksičke pogreške vrlo često samoispravljuju, što objašnjava većom osjetljivošću monitora na sadržajne riječi koje su presudne za ispravnu interpretaciju obavijesti, a slični zaključci su potvrđeni u istraživanjima govornih pogrešaka u materinskom jeziku (Bars, Motley, Mackay 1975, Garnsey, Dell 1984).

Kovač i Vidović (2010) su proučavali distribucije različitih kategorija samoispravljanja te omjere samoispravljanja i pogrešaka u hrvatskom jeziku na uzorku od 101-og ispitanika, studenata tehničkih studija u Splitu. Uočeno je da su dominantne kategorije samoispravljanja sintaktička i leksička samoispravljanja, koja zajedno obuhvaćaju četiri petine samoispravljanja pogrešaka. Također, ispitivanjem omjera samoispravljanja i pogrešaka utvrđeno je da se nešto više od 60% pogrešaka samoispravlja, što navodi na zaključak da govornik ne ispravlja svaku pogrešku u svom govoru i da se samoispravljanje ne može smatrati pravilom. Nadalje, fonološke i leksičke pogreške se uvjerljivo većinom ispravljuju (preko 85% za fonološke i gotovo 90% za leksičke pogreške), što se objašnjava njihovom informativnom važnošću, dok se morfološke i sintaktičke pogreške približno polovično samoispravljuju. Relativno niski udjel samoispravljanja neprikladnog izričaja (19.5%) u ukupnom broju samoispravljanja ukazuje da ispitanici načelno ne pokazuju tendenciju obogaćivanja obavijesnog sadržaja izričaja, što se tumači specifičnom prirodom struke i činjenicom da se u nastavi nedovoljno pozornosti posvećuje razvoju govorničkih vještina.

4. Cilj istraživanja i metodološki postupci

Cilj ovog rada je primjenom odgovarajućih statističkih testova istražiti kako specifični tip zadatka utječe na samoispravljanja određene kategorije, odnosno postoji li statistički značajna razlika u učestalosti razmatrane veličine između pojedinih zadataka, i ako postoji, između kojih zadataka je razlika prisutna.

Ispitivanje je provedeno na uzorku od 101-og ispitanika, studenata prve godine Fakulteta elektrotehnike, strojarstva i brodogradnje u Splitu. Pogreške i samoispravljanja kao varijable govorne fluentnosti ispitane su na različitim testovima govornog opisivanja.

U prvom zadatku ispitanici su pogledali crtani film *Johnny Bravo* na engleskom jeziku. Ovaj crtani film odabran je zbog pretpostavke da je relativno nepoznat ispitanicima i da sadržaj predstavlja značajniji kognitivni napor u smislu njegove diskursne organizacije. Nakon gledanja crtanog filma u trajanju od šest minuta, svaki ispitanik prepričao je svojim riječima sadržaj radnje na hrvatskom jeziku. Ispitanici nisu bili ograničeni vremenom i imali su jednu minutu za pripremu.

Drugi i treći zadatak (opisi prostorija) su uključivali opisivanje prostorno-statičnih konstelacija i njihovih međusobnih odnosa. Ispitanik je opisao izgled prostorije u kojoj je bilo šest komada namještaja, tako da je sugovornik mogao na temelju opisa rekonstruirati njezin izgled. Treći zadatak je gotovo identičan drugom, osim što je namještaj drugačije razmješten u odnosu na prethodni crtež.

U četvrtom zadatku ispitanik je oblikovao dvadeset sadržajno nepovezanih izričaja na temelju slikovnih prikaza. Tražene riječi pripadale su srodnim i nesrodnim semantičkim poljima. Sintaktički okvir nije bio zadan, a jedini preduvjet bio je da se u izričaju pojave predmeti sa crteža i odgovarajuća boja. Kao i u prethodnim zadacima, svaki ispitanik imao je jednu minutu za pripremu.

U petom zadatku ispitanik je na temelju prikaza pet sadržajno nepovezanih crteža oblikovao sadržaj priče na način da je sve prikaze povezo u jednu logičnu cjelinu. Kao i u prethodnim zadacima, sintaktički okvir nije bio zadan i ispitanici nisu bili ograničeni vremenom.

Varijable fluentnosti govora u trajanju od 7 sati i 57 minuta zabilježene su na temelju individualnog audiosnimanja govornika. Vremenski parametri

određeni su mjerenjem govornih uzoraka u programu za akustičku analizu govora *Audicity*. Ukupno je zabilježeno 1014 samoispravljanja (Kovač, Vido-
vić 2010). Pogreške i samoispravljanja identificirana su i analizirana u skladu
s Leveltovom (1983:44) strukturom ispravka koja uključuje tri dijela:

<u>'Go from left again to</u>	<u>uh..</u>	<u>from pink again to blue'</u>
Original utterance	editing	alteration
	phase	REPAIR

Prvi dio '*Go from left again to*' čini prvobitni izričaj (engl. *original utte-
rance*). Sadrži problematično mjesto ili pogrešku (engl. *reparandum*) koju
treba ispraviti ('*left*'). Pogreškom mogu biti zahvaćeni kraći i duži govorni
odsječci, počevši od jednog glasnika do cjeline teksta. Govornik može pre-
kinuti govor usred i nakon pogrešne riječi, te se također može pojaviti i od-
gođeni prekid. Prekid je ponekad popraćen određenim oblicima disfluentnos-
ti (poštapalica, tiha stanka, produžavanje vokala i slično), a taj se dio naziva
uređivačkom fazom (engl. *editing phase*). Treći dio je ispravak (engl. *repair
proper*) pogreške ili neprikladnosti.

U tablici 2 prikazana je klasifikacija pogrešaka i samoispravljanja s pripa-
dajućim primjerima iz zvučnog zapisa, a temelji se najvećim dijelom na Le-
veltovoj (1989) klasifikaciji.

Tablica 2: Klasifikacija pogrešaka i samoispravljanja primijenjena u ovom radu³

Naziv ispravka	Definicija	Primjer
Ispravak različitom infor- macijom (engl. <i>D-repair</i>)	Modifikacija sadržaja pre- dverbalnog plana. U slučaju pogreške u fazi konceptuali- zacije u procesu proizvodn- je govora govornici mogu odlučiti kodirati drugačiju informaciju od one koja sa trenutno oblikuje (Levelt 1983).	

³ Pogreška je označena zvjezdicom, a ispravak je podcrtan.

Naziv ispravka	Definicija	Primjer
a) Ispravak reorganizacijom elemenata unutar izričaja (engl. <i>ordering error repair</i>)	Ukoliko govornik želi izraziti kompleksniju informaciju, potrebno je odlučiti kako će sastavnice poredati. Za vrijeme govora, govornik može shvatiti da bi drugačiji raspored sastavnica bio adekvatniji te odlučuje kodirati dijelove namjeravane poruke drugačijim redoslijedom (Levelt 1983).	On začuje zapomaganje i ode* i oslobodi se tih šiški i ode tražiti mamu.
b) Ispravak odbacivanjem prvobitnog izričaja (engl. <i>message abandonment</i>)	Govornik odustaje od prvobitno namjeravane poruke i zamjenjuje je porukom koja ima drugačiji sadržaj (Levelt 1983).	U prvom dijelu on je* hm, majka pravi odijelo od šišarika za šumski izlet.
c) Anticipacijsko srljanje	Slično ispravku reorganizacijom elemenata unutar izričaja. Govornik anticipira dio budućeg govornog programa i realizira ga, a zatim ga naglo prekida i vraća na pravi program (Horga 1997).	Satovi su počeli zvonit, šta je pro* hm uspavanog medvjeda probudilo.
Ispravak neprikladnog izričaja (engl. <i>A-repair</i>)		
a) Ispravak nepreciznog izričaja (engl. <i>appropriacy-A-repair</i>)	Prvobitni izričaj nije dovoljno precizan te govornik želi pružiti dodatnu informaciju kako bi se izričaj pobliže objasnio (Levelt 1983).	I probudi medvjeda koji se predstavi kao Kronos, to jest, ovaj, gospodar vremena.
b) Ispravak potencijalno dvosmislenog izričaja ili dijela izričaja (engl. <i>ambiguity repair</i>)	Prvobitni izričaj može biti potencijalno dvosmislen i govornik ga pobliže objašnjava.	Uspije ga nagovoriti da mu da, hm, šansu da ga, da ga opet uspava, hm, hm, dade mu dvadeset, Kronos mu da dvadeset minuta.

Naziv ispravka	Definicija	Primjer
<p>c) Ispravak „lošeg” jezika (engl. <i>repairs for good language</i>)</p> <p>Ispravak pogrešaka (engl. <i>Error-E-repair</i>)</p>	<p>Ispravak dijela izričaja koji je pragmatički prihvatljiv, ali ga govornik ne smatra dovoljno sofisticiranim (Bredart 1991).</p>	<p>Johnny čeka cijeli dan, znači, mater, <u>mamu</u> i ona se, hm, ne vrati nekoliko dana.</p>
<p>a) Ispravak leksičke pogreške (engl. <i>lexical error repair</i>)</p> <p>b) Ispravak morfološke pogreške (engl. <i>morphological error repair</i>)</p>	<p>Ispravak pogrešno aktivirane leme (Levelt 1983).</p> <p>Pogreške kongruencije. Govornik mora odabrati i izgovoriti morfološki oblik neke riječi koji ovisi o riječi koja će u govoru biti ostvarena kasnije, a govornik je u svom govornom programu još nije odabrao. Moguće su pogreške u rodu, broju, padežu ili govornik tvori morfološki oblik koji nije u skladu s jezičnom normom (Horga 1997).</p>	<p>Hm, moj brat voli jesti puno zel,* <u>žutih</u> banana.</p> <p>Tražio je po, hm, cijelom* š, <u>cijeloj</u> šumi, no nije je mogao pronaći.</p>
<p>c) Ispravak sintaktičke pogreške (engl. <i>syntactic error repair</i>)</p>	<p>Započeta sintaktička konstrukcija koja vodi do „mrtve točke” i koju govornik ispravlja. Ponekad je sintaksa izričaja potpuno konfuzna te govornik prekida izričaj i ponovno ga započinje (engl. <i>restart</i>). U ovu kategoriju samoispravljanja uključena je i preformulacija izričaja (engl. <i>reformulation</i>) i ispravljanje pogrešnog reda riječi (engl. <i>wrong word order</i>).</p>	<p>Hm, ipak je Johnny Bravo uspio pobjeći ali ga je me,* <u>ali je medvjed krenuo za njim.</u></p>

Naziv ispravka	Definicija	Primjer
d) Ispravak fonološke pogreške (engl. <i>phonological error repair</i>)	Pogreška u ostvarivanju izgovornog programa (Horga 1997).	Zatim ga je medvjed, hm, hm, htio pojesti jer je ogladnio jer se,* šest mjeseci ništa nije jeo.

U nastavku slijede rezultati analize korpusa, pri čemu se koriste odgovarajuće oznake u svrhu lakšeg snalaženja prilikom povezivanja rezultata s pojedinim zadacima: zadatak 1 – FILM, zadatak 2 – SOBA1, zadatak 3 – SOBA2, zadatak 4 – IZORE i zadatak 5 – STRIP.

5. Rezultati istraživanja

U ovom poglavlju razmatra se kako kognitivna složenost pojedinog zadatka utječe na samoispravljanja određene kategorije, odnosno postoje li između zadataka statistički značajne razlike u učestalosti određene kategorije samoispravljanja. Budući da je trajanje govora u riječima po ispitaniku promjenljiva veličina u svakom zadatku, a kako bi se omogućila usporedba različitih zadataka primjenom odgovarajućih statističkih testova, potrebno je proračune izvršiti redukcijom odgovarajuće kategorije samoispravljanja po ispitaniku na unaprijed specificirani broj riječi. Kako je u dostupnoj literaturi taj broj u znatnom broju slučajeva 100, isti pristup odabran je u ovom radu (npr. Bortfeld i sur. 2001).

Kako su u ovom radu istraživanja utjecaja kognitivne složenosti na pojavnost različitih kategorija samoispravljanja u svakom zadatku izvedena na istim ispitanicima (101-om studentu FESB-a), te posljedično postoji pet uzoraka dobivenih na istim ispitanicima, radi se o ponovljenim mjerenjima (engl. *repeated measures*), odnosno o zavisnim uzorcima.

Za testiranje normalnosti odabran je Shapiro-Wilkov test normalnosti (Marques de Sá 2007) koji je istaknut u recentnim radovima kao najefikasniji test normalnosti (Thode 2002, Zhang, Yuehua 2005, Keskin 2006, HENDERSON 2006, Coin 2008). Ako sukladno ovom testu pojedine distribucije statistički značajno odstupaju od normalne distribucije, tada se odabire Friedmanov neparametrijski test (Field 2005, Marques de Sá 2007, Demšar 2006) kao vjerojatno najčešće korišteni (Al-Subaihi 2000) i najpoznatiji (Van de Wiel 2004) neparametrijski test za ponovljena mjerenja u slučaju postojanja tri ili

više zavisnih uzoraka. Neparametrijski testovi se u literaturi nazivaju i *distribution-free* testovima, te je iz samog naziva vidljivo da ovaj tip testova ne postavlja zahtjev za normalnošću distribucije, kao ni zahtjev za homogenošću varijanci (Montgomery, Runger 2003). U dijelu objavljene literature navodi se da je nedostatak neparametrijskih testova što su nešto manje učinkoviti od parametrijskih testova, ali samo ukoliko su ispunjeni uvjeti za primjenu parametrijskih testova. Ako uvjeti za primjenu parametrijskih testova nisu ispunjeni, superiornost neparametrijskih testova nije sporna (Montgomery, Runger 2003).

Ako statistički značajne razlike između zadataka u učestalostima određene kategorije samoispravljanja postoje, Friedmanov test ne daje odgovor između kojih zadataka razlike postoje. Odgovor na to pitanje daje Dunnov test kao odabrani test višestrukih usporedbi (Daniel 1990, Pett 1997), koji je učinkovit test s opreznom procjenom statistički značajnih razlika između uspoređenih parova (Pett 1997). Komparacije se mogu provesti samo za izabrane parove zadataka ili za sve moguće kombinacije parova. U slučaju provedbe višestrukih usporedbi s nepromijenjenim pragom značajnosti $\alpha = 0.05$ za svaki par, potrebno je voditi računa da s brojem komparacija znatno raste i sveukupna (kumulativna) vjerojatnost pogreške tipa I, odnosno vjerojatnost odbacivanja nul-hipoteze kada je ona istinita barem u jednom slučaju usporedbe (npr. za 5 uspoređenih parova ona je 0.226, dok za 10 komparacija, što je maksimalni broj u slučaju postojanja 5 grupa, ona čak prelazi 0.4). Rješenje može biti u smanjenju praga značajnosti za svaku komparaciju na vrijednost koja osigurava da kumulativna vjerojatnost pogreške tipa I ne prelazi 0.05. Iznos praga značajnosti za svaku usporedbu obrnuto je proporcionalan s brojem usporedbi (npr. za 5 uspoređenih parova on je 0.0102). S obzirom da se smanjenjem praga značajnosti za svaku komparaciju ne samo dobivaju vrlo restriktivne vrijednosti, nego i povećava rizik od pogreške tipa II (nul-hipoteza nije odbačena, iako je alternativna hipoteza točna), može se izvesti zaključak da je korisno napraviti usporedbe samo za izabrane parove. Na taj način se smanjuje broj usporedbi, a time i rizik od pogreške tipa II za svaku komparaciju, te se izbjegavaju restriktivne vrijednosti praga značajnosti za svaku komparaciju. Odluka o izboru parova koje treba usporediti može se donijeti na temelju poznavanja statističkih veličina i vrijednosti pojedinog uzorka. Zaključno, preporučljivo je biti izbirljiv u odabiru parova za usporedbu (Marques de Sá 2007).

5.1. Samoispravljanje pogrešaka

a) Samoispravljanje sintaktičkih pogrešaka

U tablici 3 prikazane su uzoračke vrijednosti i veličine za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi. Rezultati Shapiro-Wilkovog testa normalnosti za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi ukazuju da sve populacije statistički značajno odstupaju od normalne distribucije, tablica 4. Rezultati Friedmanovog testa za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi predočeni su u tablici 5. *P*-vrijednost je manja od 0.0001, što znači da postoje statistički značajne razlike između pojedinih zadataka. Uzimajući u obzir da je u FILM-u već medijan različit od nule, dok su u ostalim zadacima i gornji kvantili jednaki nuli, osim u IZORE-u, gdje je medijan jednak nuli, tablica 3, Dunnov test višestrukih usporedbi za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi proveden je za kombinacije parova zadataka koje sadrže FILM. Naime, FILM se uspoređuje sa svakim od ostalih zadataka, tablica 6, te proizlazi da se u FILM-u pojavljuje statistički značajno veća učestalost samoispravljanja sintaktičkih pogrešaka. Kod opisivanja strukture kronološkog događaja (FILM) uzastopni govorni činovi organiziraju se *on line*, a problemi u planiranju i izvedbi rješavaju se *ad hoc*. Preporučavanje radnje je kognitivno složen i zahtjevan proces, pri čemu je govornikova pažnja više usmjerena prema planiranju i organizaciji govornih činova pod pritiskom vremena, a govorni sustav ponekad ne uspijeva uskladiti procese proizvodnje na svim razinama. Kada je informacija koju treba prenijeti kompleksna i ako uključuje nekoliko uzastopnih govornih činova, govornik mora odlučiti kako će organizirati informaciju. Stoga je paralelno i neproblematično procesiranje ponekad otežano, a očituje se u učestalom pojavljivanju različitih oblika disfluentnosti, među kojima su i sintaktičke pogreške te posljedično samoispravljanja.

Tablica 3: Uzoračke vrijziti i veličine za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi

ER_S	FILM	SOBA1	SOBA2	IZORE	STRIP
n	101	101	101	101	101
x_{min}	0	0	0	0	0
D₁	0	0	0	0	0
Q₁	0	0	0	0	0
Me	0.535	0	0	0	0
Q₃	0.948	0	0	0.758	0
D₉	1.399	2.381	1.992	1.609	1.956
x_{max}	2.392	3.448	3.571	3.158	4.000
d	2.392	3.448	3.571	3.158	4.000
d_Q	0.948	0	0	0.758	0
\bar{x}	0.574	0.493	0.381	0.436	0.434
σ	0.559	0.952	0.910	0.747	0.879
σ^2	0.312	0.906	0.828	0.558	0.773
S_{\bar{x}}	0.056	0.095	0.091	0.074	0.088
V	97.46 %	193.17 %	238.68 %	171.44 %	202.42 %
α_3	0.761	1.665	2.275	1.788	1.929
α_4	0.012	1.271	3.933	2.600	2.928

n – veličina uzorka, *x_{min}* – minimalna vrijednost, *D₁* – prvi decil, *Q₁* – donji kvartil, *Me* – medijan, *Q₃* – gornji kvartil, *D₉* – deveti decil, *x_{max}* – maksimalna vrijednost, *d* – raspon uzorka, *d_Q* – interkvartil, \bar{x} – aritmetička sredina, σ – standardna devijacija, σ^2 – varijanca, *S _{\bar{x}}* – standardna pogreška, *V* – koeficijent varijacije, α_3 – koeficijent asimetrije, α_4 – koeficijent zaobljenosti

Tablica 4: Shapiro-Wilkov test normalnosti za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi

Shapiro-Wilk	FILM	SOBA1	SOBA2	IZORE	STRIP
W	0.8867	0.5713	0.4759	0.6536	0.5581
p	< 0.0001	< 0.0001	< 0.0001	< 0.0001	< 0.0001

W – Shapiro-Wilkova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je populacija normalno distribuirana

Tablica 5: Friedmanov test za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	36.233	< 0.0001

n – veličina uzorka, *df* – stupnjevi slobode, *F_r* – Friedmanova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je nul-hipoteza točna

Tablica 6: Dunnov test višestrukih usporedbi za učestalosti samoispravljanja sintaktičkih pogrešaka na 100 riječi

Dunn	<i>Razlika u sumi rangova</i>	<i>Statistički značajna razlika</i>
FILM – SOBA1	77	Da
FILM – SOBA2	94	Da
FILM – IZORE	73	Da
FILM – STRIP	81	Da

b) Samoispravljanje leksičkih pogrešaka

Iduća razmatrana kategorija samoispravljanja pogrešaka je samoispravljanje leksičkih pogrešaka na 100 riječi, čije su uzoračke vrijednosti i veličine vidljive iz tablice 7. Provedbom Shapiro-Wilkovog testa normalnosti za učestalosti samoispravljanja leksičkih pogrešaka na 100 riječi, tablica 8, zaključuje se da sve distribucije statistički značajno odstupaju od normalne distribucije. U tablici 9 prikazani su rezultati Friedmanovog testa za učestalosti samoispravljanja leksičkih pogrešaka na 100 riječi. *P*-vrijednost Friedmanovog testa, 0.2881, značajno je veća od praga značajnosti, što znači da nisu dobivene statistički značajne razlike između pojedinih zadataka.

Tablica 7: Uzoračke vrijednosti i veličine za učestalosti samoispravljanja leksičkih pogrešaka na 100 riječi

ER_L	FILM	SOBA1	SOBA2	IZORE	STRIP
n	101	101	101	101	101
x_{min}	0	0	0	0	0
D₁	0	0	0	0	0
Q₁	0	0	0	0	0
Me	0	0	0	0	0
Q₃	0.601	1.118	0.355	0.955	0
D₉	0.936	2.527	2.638	1.551	1.880
x_{max}	2.033	4.762	4.878	3.077	4.545
d	2.033	4.762	4.878	3.077	4.545
d_Q	0.601	1.118	0.355	0.955	0
\bar{x}	0.302	0.594	0.580	0.458	0.405
σ	0.450	1.077	1.147	0.703	0.899
σ^2	0.203	1.160	1.316	0.494	0.808
S_{\bar{x}}	0.045	0.107	0.114	0.070	0.089
V	148.97 %	181.21 %	197.74 %	153.47 %	221.72 %
α_3	1.570	1.783	1.979	1.414	2.398
α_4	2.228	2.556	3.166	1.289	5.838

n – veličina uzorka, *x_{min}* – minimalna vrijednost, *D₁* – prvi decil, *Q₁* – donji kvartil, *Me* – medijan, *Q₃* – gornji kvartil, *D₉* – deveti decil, *x_{max}* – maksimalna vrijednost, *d* – raspon uzorka, *d_Q* – interkvartil, \bar{x} – aritmetička sredina, σ – standardna devijacija, σ^2 – varijanca, *S _{\bar{x}}* – standardna pogreška, *V* – koeficijent varijacije, α_3 – koeficijent asimetrije, α_4 – koeficijent zaobljenosti

Tablica 8: Shapiro-Wilkov test normalnosti za učestalosti samoispriavljanja leksičkih pogrešaka na 100 riječi

Shapiro-Wilk	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
W	0.7196	0.6198	0.5775	0.7001	0.5197
p	< 0.0001	< 0.0001	< 0.0001	< 0.0001	< 0.0001

W – Shapiro-Wilkova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je populacija normalno distribuirana

Tablica 9: Friedmanov test za učestalosti samoispriavljanja leksičkih pogrešaka na 100 riječi

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	4.992	0.2881

n – veličina uzorka, *df* – stupnjevi slobode, *F_r* – Friedmanova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je nul-hipoteza točna

c) Samoispriavljanje morfoloških pogrešaka

Uzoračke vrijednosti i veličine za učestalosti samoispriavljanja morfoloških pogrešaka na 100 riječi vidljive su iz tablice 10. Provođenje Shapiro-Wilkovog testa za učestalosti samoispriavljanja morfoloških pogrešaka na 100 riječi u svakom zadatku, tablica 11, dovodi do zaključka da sve distribucije statistički značajno odstupaju od normalne distribucije. U tablici 12 prikazani su rezultati Friedmanovog testa, pri čemu je *p*-vrijednost testa manja od 0.0001, što ukazuje na postojanje statistički značajne razlike između pojedinih zadataka. Kako su za zadatke SOBA1 i SOBA2 sve tablične vrijednosti uzoraka jednake nuli sve do maksimalne vrijednosti, dok je u FILM-u već gornji kvartil različit od nule, tablica 10, Dunnovim testom se zadaci SOBA1 i SOBA2 uspoređuju s FILM-om, tablica 13. Dakle, parovi za usporedbu učestalosti samoispriavljanja morfoloških pogrešaka na 100 riječi su: FILM – SOBA1 i FILM – SOBA2. U FILM-u su resursi pažnje više usmjereni prema procesima planiranja izričaja, a manje vremena preostaje za nadgledavanje ostalih procesa govorne proizvodnje. Tako ispitanik češće izabire

pogrešan morfološki oblik riječi, zato što u svom programu u određenom trenutku još nije odabrao riječ koja će biti izgovorena kasnije, za razliku od zadataka SOBA1 i SOBA2 koji kraće traju i gdje vrijeme pripreme te slikovni prikaz govorniku pomažu da odabere pripadajući morfološki nastavak odgovarajuće leksičke jedinice.

Tablica 10: Uzoračke vrijednosti i veličine za učestalosti samoispravljanja morfoloških pogrešaka na 100 riječi

ER_M	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
n	101	101	101	101	101
x_{min}	0	0	0	0	0
D_1	0	0	0	0	0
Q_1	0	0	0	0	0
Me	0	0	0	0	0
Q_3	0.245	0	0	0	0
D_9	0.644	0	0	0.934	1.060
x_{max}	1.163	3.448	1.250	1.676	3.922
d	1.163	3.448	1.250	1.676	3.922
d_Q	0.245	0	0	0	0
\bar{x}	0.153	0.091	0.012	0.177	0.227
σ	0.283	0.484	0.124	0.404	0.671
σ^2	0.080	0.234	0.015	0.163	0.450
$S_{\bar{x}}$	0.028	0.048	0.012	0.040	0.067
V	184.29 %	530.91 %	1004.99 %	228.11 %	296.34 %
α_3	1.752	5.751	10.050	2.150	3.506
α_4	2.059	34.077	101.000	3.512	13.011

n – veličina uzorka, x_{min} – minimalna vrijednost, D_1 – prvi decil, Q_1 – donji kvartil, Me – medijan, Q_3 – gornji kvartil, D_9 – deveti decil, x_{max} – maksimalna vrijednost, d – raspon uzorka, d_Q – interkvartil, \bar{x} – aritmetička sredina, σ – standardna devijacija, σ^2 – varijanca, $S_{\bar{x}}$ – standardna pogreška, V – koeficijent varijacije, α_3 – koeficijent asimetrije, α_4 – koeficijent zaobljenosti

Tablica 11: Shapiro-Wilkov test normalnosti za učestalosti samoispravljanja morfoloških pogrešaka na 100 riječi

Shapiro-Wilk	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
W	0.6113	0.1883	0.0746	0.4978	0.3922
p	< 0.0001	< 0.0001	< 0.0001	< 0.0001	< 0.0001

W – Shapiro-Wilkova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je populacija normalno distribuirana

Tablica 12: Friedmanov test za učestalosti samoispravljanja morfoloških pogrešaka na 100 riječi

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	38.819	< 0.0001

n – veličina uzorka, *df* – stupnjevi slobode, *F_r* – Friedmanova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je nul-hipoteza točna

Tablica 13: Dunnov test višestrukih usporedbi za učestalost samoispravljanja morfoloških pogrešaka na 100 riječi

Dunn	Razlika u sumi rangova	Statistički značajna razlika
FILM – SOBA1	59	Da
FILM – SOBA2	67	Da

d) Samoispravljanje fonoloških pogrešaka

Uzoračke vrijednosti i veličine za učestalosti samoispravljanja fonoloških pogrešaka na 100 riječi vidljive su iz tablice 14. Prema Shapiro-Wilkovom testu za učestalosti samoispravljanja fonoloških pogrešaka na 100 riječi u svakom zadatku, tablica 15, sve distribucije značajno odstupaju od nor-

malne distribucije. U tablici 16 prikazani su rezultati Friedmanovog testa. P -vrijednost testa jednaka je 0.3464, što znači da između pojedinih zadataka nisu dobivene statistički značajne razlike za učestalosti samoispravljanja fonoloških pogrešaka na 100 riječi.

Tablica 14: Uzoračke vrijednosti i veličine za učestalosti samoispravljanja fonoloških pogrešaka na 100 riječi

ER_F	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
n	101	101	101	101	101
x_{\min}	0	0	0	0	0
D_1	0	0	0	0	0
Q_1	0	0	0	0	0
Me	0	0	0	0	0
Q_3	0	0	0	0	0
D_9	0.316	0	0	0	0
x_{\max}	1.695	6.897	5.714	2.778	2.632
d	1.695	6.897	5.714	2.778	2.632
d_Q	0	0	0	0	0
\bar{x}	0.057	0.182	0.106	0.097	0.078
σ	0.207	0.915	0.633	0.398	0.395
σ^2	0.043	0.837	0.401	0.158	0.156
$S_{\bar{x}}$	0.021	0.091	0.063	0.040	0.039
V	361.80 %	502.42 %	598.21 %	410.16 %	506.39 %
α_3	5.627	5.751	7.606	4.733	5.510
α_4	39.810	35.364	63.935	24.551	30.899

n – veličina uzorka, x_{\min} – minimalna vrijednost, D_1 – prvi decil, Q_1 – donji kvartil, Me – medijan, Q_3 – gornji kvartil, D_9 – deveti decil, x_{\max} – maksimalna vrijednost, d – raspon uzorka, d_Q – interkvartil, \bar{x} – aritmetička sredina, σ – standardna devijacija, σ^2 – varijanca, $S_{\bar{x}}$ – standardna pogreška, V – koeficijent varijacije, α_3 – koeficijent asimetrije, α_4 – koeficijent zaobljenosti

Tablica 15: Shapiro-Wilkov test normalnosti za učestalosti samoispravljanja fonoloških pogrešaka na 100 riječi

Shapiro-Wilk	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
W	0.3028	0.2051	0.1617	0.2664	0.1997
p	< 0.0001	< 0.0001	< 0.0001	< 0.0001	< 0.0001

W – Shapiro-Wilkova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je populacija normalno distribuirana

Tablica 16: Friedmanov test za učestalosti samoispravljanja fonoloških pogrešaka na 100 riječi

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	4.468	0.3464

n – veličina uzorka, *df* – stupnjevi slobode, *F_r* – Friedmanova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je nul-hipoteza točna

5.2. Samoispravljanja neprikladnog izričaja

U tablici 17 prikazane su uzoračke vrijednosti i veličine vezane za učestalosti samoispravljanja neprikladnog izričaja. U tablici 18 vidljivi su rezultati Shapiro-Wilkovog testa za učestalosti samoispravljanja neprikladnog izričaja. Sukladno ovom testu može se primijetiti da sve distribucije značajno odstupaju od normalne distribucije. U tablici 19 prikazani su rezultati Friedmanovog testa za učestalosti samoispravljanja neprikladnog izričaja. *P*-vrijednost Friedmanovog testa je manja od 0.0001, što znači da su dobivene statistički značajne razlike između pojedinih zadataka. Uzimajući u obzir da su u zadacima SOBA2 i STRIP sve tablične vrijednosti jednake nuli do devetog decila, tablica 17, navedeni zadaci se uspoređuju s ostalim zadacima. Rezultati Dunnovog testa višestrukih usporedbi prikazani su u tablici 20. Statistički značajna razlika u učestalostima samoispravljanja neprikladnog izričaja postoji između FILM-a i zadatka SOBA2. U zadatku FILM nameće se potreba za specificiranjem obavijesnog sadržaja na diskursnoj razini. S druge strane,

SOBA2 je ponovljeni zadatak i govornik ne osjeća potrebu za dodatnim preciziranjem, s obzirom da je to učinio u zadatku SOBA1 i pretpostavlja da je sugovornik već upoznat sa sadržajem na dovoljno eksplicitan način. Statistički značajna razlika postoji između zadataka FILM i STRIP. U STRIP-u je govornik fokusiran na povezivanje elemenata u logičku cjelinu i ne pokazuje posebnu sklonost prema preciziranju ili obogaćivanju sadržaja.

Tablica 17: Uzoračke vrijednosti i veličine za učestalosti samoispravljanja neprikladnog izričaja na 100 riječi

AR	FILM	SOBA1	SOBA2	IZORE	STRIP
n	101	101	101	101	101
x_{\min}	0	0	0	0	0
D_1	0	0	0	0	0
Q_1	0	0	0	0	0
Me	0	0	0	0	0
Q_3	0.480	1.190	0	0.725	0
D_9	0.981	1.992	1.106	1.431	1.060
x_{\max}	2.076	5.556	3.333	4.000	3.226
d	2.076	5.556	3.333	4.000	3.226
d_Q	0.480	1.190	0	0.725	0
\bar{x}	0.330	0.587	0.220	0.400	0.210
σ	0.447	1.083	0.676	0.771	0.592
σ^2	0.200	1.173	0.457	0.594	0.350
$S_{\bar{x}}$	0.044	0.108	0.067	0.077	0.059
V	135.63 %	184.37 %	306.76 %	192.68 %	281.99 %
α_3	1.620	2.134	3.096	2.446	3.081
α_4	2.693	5.032	8.754	6.672	9.514

n – veličina uzorka, x_{\min} – minimalna vrijednost, D_1 – prvi decil, Q_1 – donji kvartil, Me – medijan, Q_3 – gornji kvartil, D_9 – deveti decil, x_{\max} – maksimalna vrijednost, d – raspon uzorka, d_Q – interkvartil, \bar{x} – aritmetička sredina, σ – standardna devijacija, σ^2 – varijanca, $S_{\bar{x}}$ – standardna pogreška, V – koeficijent varijacije, α_3 – koeficijent asimetrije, α_4 – koeficijent zaobljenosti

Tablica 18: Shapiro-Wilkov test normalnosti za učestalosti samoispravljanja neprikladnog izričaja na 100 riječi

Shapiro-Wilk	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
W	0.7609	0.6148	0.3685	0.5952	0.4118
p	< 0.0001	< 0.0001	< 0.0001	< 0.0001	< 0.0001

W – Shapiro-Wilkova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je populacija normalno distribuirana

Tablica 19: Friedmanov test za učestalosti samoispravljanja neprikladnog izričaja na 100 riječi

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	26.360	< 0.0001

n – veličina uzorka, *df* – stupnjevi slobode, *F_r* – Friedmanova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je nul-hipoteza točna

Tablica 20: Dunnov test višestrukih usporedbi za učestalosti samoispravljanja neprikladnog izričaja na 100 riječi

Dunn	Razlika u sumi rangova	Statistički značajna razlika
FILM – SOBA2	68.5	Da
FILM – STRIP	65.5	Da
SOBA1 – SOBA2	44	Ne
SOBA1 – STRIP	41	Ne
SOBA2 – IZORE	-42	Ne
IZORE – STRIP	39	Ne

5.3. Samoispravljanje različitom informacijom

U tablici 21 predočene su uzoračke vrijednosti i veličine za učestalosti samoispravljanja različitom informacijom. Shapiro-Wilkov test normalnosti za učestalosti samoispravljanja različitom informacijom na 100 riječi, tablica 22, još jednom rezultira zaključkom da sve distribucije statistički značajno odstupaju od normalne distribucije. P -vrijednost Friedmanovog testa je manja od 0.0001, tablica 23, što znači da su dobivene statistički značajne razlike između pojedinih zadataka.

Tablica 21: Uzoračke vrijednosti i veličine za učestalosti samoispravljanja različitom informacijom na 100 riječi

DR	FILM	SOBA1	SOBA2	IZORE	STRIP
n	101	101	101	101	101
x_{\min}	0	0	0	0	0
D_1	0	0	0	0	0
Q_1	0	0	0	0	0
Me	0.337	0	0	0	0
Q_3	0.551	0	0	0.775	0
D_9	0.971	1.762	1.466	1.149	2.075
x_{\max}	1.796	5.128	3.704	2.000	6.897
d	1.796	5.128	3.704	2.000	6.897
d_Q	0.551	0	0	0.775	0
\bar{x}	0.357	0.322	0.315	0.318	0.420
σ	0.408	0.896	0.733	0.527	1.089
σ^2	0.166	0.803	0.537	0.278	1.186
$S_{\bar{x}}$	0.040	0.089	0.073	0.052	0.108
V	114.57 %	278.48 %	232.69 %	165.58 %	259.07 %
α_3	1.178	3.117	2.385	1.373	3.267
α_4	1.133	10.328	5.390	0.714	13.062

n – veličina uzorka, x_{\min} – minimalna vrijednost, D_1 – prvi decil, Q_1 – donji kvartil, Me – medijan, Q_3 – gornji kvartil, D_9 – deveti decil, x_{\max} – maksimalna vrijednost, d – raspon uzorka, d_Q – interkvartil, \bar{x} – aritmetička sredina, σ – standardna devijacija, σ^2 – varijanca, $S_{\bar{x}}$ – standardna pogreška, V – koeficijent varijacije, α_3 – koeficijent asimetrije, α_4 – koeficijent zaobljenosti

Tablica 22: Shapiro-Wilkov test normalnosti za učestalosti samoispravljanja različitom informacijom na 100 riječi

Shapiro-Wilk	FILM	SOBA1	SOBA2	IZORE	STRIP
W	0.8298	0.4172	0.4945	0.6472	0.4496
p	< 0.0001	< 0.0001	< 0.0001	< 0.0001	< 0.0001

W – Shapiro-Wilkova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je populacija normalno distribuirana

Tablica 23: Friedmanov test za učestalosti samoispravljanja različitom informacijom na 100 riječi

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	34.762	< 0.0001

n – veličina uzorka, *df* – stupnjevi slobode, *F_r* – Friedmanova testovna veličina, *p* – vjerojatnost dobivanja istih ili ekstremnijih vrijednosti testovne veličine od dobivene vrijednosti, kada je nul-hipoteza točna

Uzimajući u obzir da je u FILM-u već medijan različit od nule, tablica 21, Dunnov test višestrukih usporedbi za samoispravljanja različitom informacijom na 100 riječi proveden je za kombinacije parova zadataka koje sadrže FILM. Dakle, prvi zadatak uspoređuje se sa svakim od ostalih zadataka, tablica 24. Rezultati analize samoispravljanja različitom informacijom ukazuju da postoji statistički značajna razlika između FILM-a i svih ostalih zadataka, osim IZORE-a. Kod prepričavanja kronološkog redoslijeda događaja (FILM) govornik treba povezati i linearno organizirati govorne činove. Princip prirodnog poretka je teže primijeniti u domeni opisivanja dinamičnih konstelacija zbog dinamičnih aspekata događaja, za razliku od statičnih konstelacija (SOBA1 i SOBA2) (Levelt 1989). U FILM-u informacija uključuje uzastopne govorne činove, pri čemu se učestalije javljaju poteškoće u fazi konceptualizacije. Konceptualizator u tom slučaju nije ispravno poredao informacije ili je pogrešno kodirao informaciju, što rezultira neadekvatnim predverbalnim planom. Govornik nailazi na problem organizacije elemenata unutar izričaja ili odustaje od prvobitnog izričaja zato što drugačiju obavijest u tom trenut-

ku smatra relevantnijom ili jednostavnijom za oblikovanje. S druge strane, kod osjetno kraćih intervala govora svojstvenih zadacima SOBA1, SOBA2 i STRIP u odnosu na trajanje govora u FILM-u, vrijeme pripreme govornici- ma pomaže konceptualizirati poruku.

Tablica 24: Dunnov test višestrukih usporedbi za učestalosti samoispravljanja različitom informacijom na 100 riječi

Dunn	Razlika u sumi rangova	Statistički značajna razlika
FILM – SOBA1	82.5	Da
FILM – SOBA2	79.5	Da
FILM – IZORE	53.5	Ne
FILM – STRIP	74.5	Da

6. Zaključak

Zadaci odabrani u svrhu istraživanja utjecaja kognitivne složenosti pojedinog tipa zadatka na samoispravljanja uključuju opisivanje kronološkog slijeda radnje animiranog filma (FILM), opisivanje prostornih odnosa (SOBA1 i SOBA2), sadržajno neovisnih izričaja (IZORE), te oblikovanje priče na temelju slikovnih prikaza (STRIP). Kod prepričavanja radnje filma pojavljuje se statistički značajno više samoispravljanja gramatičkih (sintaktičkih i morfoloških) pogrešaka u odnosu na ostale zadatke, dok učestalost samoispravljanja leksičkih i fonoloških pogrešaka nije uvjetovana specifičnom prirodom zadatka. Kod opisivanja kronološkog slijeda sadržaja radnje animiranog filma govornikova pažnja je više usmjerena prema planiranju i organizaciji govornih činova pod pritiskom vremena, odnosno procesima linearizacije makrorazine. Zbog toga govornikov sustav ne uspijeva uvijek uskladiti procese proizvodnje na svim razinama, a poteškoće u planiranju rezultiraju većom učestalošću sintaktičkih i morfoloških pogrešaka koje govornik ispravlja.

Statistički značajna razlika u učestalostima samoispravljanja neprikladnog izričaja postoji između FILM-a i zadatka SOBA2. Prepričavanje radnje nameće potrebu za specifikiranjem obavijesnog sadržaja na diskursnoj razini kako bi sugovornik lakše interpretirao obavijest. S druge strane, SOBA2 je ponovljeni zadatak i govornik ne osjeća potrebu za dodatnim preciziranjem i pretpostavlja da je sugovornik već dovoljno upoznat sa sadržajem. Statis-

tički značajna razlika postoji između zadataka FILM i STRIP. U STRIP-u je govornik fokusiran na povezivanje elemenata u logičku cjelinu i ne pokazuje posebnu sklonost prema doradivanju ili obogaćivanju sadržaja.

Kognitivna kompleksnost zadatka FILM očituje se i u većoj učestalosti samoispravljanja različitom informacijom, što upućuje na poteškoće u fazi konceptualizacije. Govornik nailazi na problem organizacije elemenata unutar izričaja ili odustaje od prvobitnog izričaja zato što drugačiju obavijest u određenom trenutku smatra relevantnijom ili jednostavnijom za oblikovanje. S druge strane, osjetno kraći intervali govora svojstveni ostalim zadacima, vrijeme pripreme te jednostavnija sadržajna struktura olakšavaju procese jezične obrade počevši od konceptualizacije poruke, oblikovanja morfosintaktičkog okvira do same artikulacije.

Zaključci proizišli iz ovog istraživanja mogli bi naći svoju praktičnu primjenu u nastavi kolegija Komunikacijske vještine. U nastavi je potrebno unaprjeđivati govorničke vještine i opću fluentnost s posebnim naglaskom na zadatke koji uključuju prepričavanje kronološkog tijeka događaja. Također, potrebno je naglasiti da je ovo istraživanje bilo usmjereno prema populaciji studenata tehničkih studija, te da bi buduća istraživanja mogla dati odgovor na pitanje u kojoj mjeri zaključci ovog rada vrijede i za opću populaciju.

Literatura

- AL-SUBAIHI A. A., 2000, A Monte Carlo Study of the Friedman and Conover Tests in the Single-Factor Repeated Measures Design, *J. Statist. Comput. Simul.* 65, s. 203–223.
- BAARS B. J., MOTLEY M. T., MACKAY D. G., 1975, Output editing for lexical status in artificially elicited slips of the tongue, *Journal of Verbal Learning and Verbal Behaviour* 14, s. 382–391.
- BORTFELD H., LEON S. D., BLOOM J. E., SCHOBBER M. F., BRENNAN S. E., 2001, Disfluency Rates in Conversation: Effects of Age, Relationship, Topic, Role, and Gender. *Language and Speech* 44(2), s. 123–147.
- BREDART S., 1991, Word interruption in self-repairing, *Journal of Psycholinguistic Research* 20, s. 123–137.
- COIN D., 2007, A goodness-of-fit test for normality based on polynomial regression, *Computational Statistics and Data Analysis* 52, s. 2185–2198.
- DANIEL W. W., 1990, *Applied Nonparametric Statistics*, PWS-Kent Publishing Company.

- DELL G. S., SCHWARTZ M. F., MARTIN N., SAFFRAN E. M., GAGNON D. A., 1997, Lexical access in aphasic and non aphasic speakers, *Psychological Review* 104, s. 801–838.
- DEMŠAR J., 2006, Statistical Comparisons of Classifiers over Multiple Data Sets, *Journal of Machine Learning Research* 7, s. 1–30.
- ERDELJAC V., 2009, *Mentalni leksikon: modeli i činjenice*, Zagreb: Ibis grafika.
- FATHMAN A. K., 1980, Repetition and correction as an indication of speech planning and execution processes among second language learners, w: H. W. Dechert i M. Raupach (red.), *Towards a crosslinguistic assessment of speech production*, Frankfurt: Peter D. Lang, s. 77–85.
- FIELD A., 2005, *Discovering Statistics using SPSS*, London: SAGE Publications.
- GARNSEY S. M., DELL S. G., 1984, Some neurolinguistic implications of prearticulatory editing in production, *Brain and language* 23, s. 64–73.
- HENDERSON A. R., 2006, Testing experimental data for univariate normality, *Clinica Chimica Acta* 366, s. 112–129.
- HORGA D., 1997, Samoispravljanje u govornoj proizvodnji, *Suvremena lingvistika* 43–44, s. 91–104.
- KESKIN S., 2006, Comparison of Several Univariate Normality Tests Regarding Type I Error Rate and Power of the Test in Simulation based Small Samples, *Journal of Applied Science Research* 2 (5), s. 296–300.
- KORMOS J., 2000, The role of attention in monitoring second language speech production, *Language Learning* 50, s. 343–384.
- KORMOS J., 2006, *Speech Production and Second Language Acquisition*, New York–London: Lawrence Erlbaum Associates.
- KOVAČ M. M., VIDOVIĆ A., 2010, Samoispravljanja u hrvatskom jeziku, *Časopis za fonetiku „Govor” XXVII* (2), s. 91–114.
- LENNON P., 1990, Investigating fluency in EFL: A quantitative approach, *Language Learning* 40, s. 387–417.
- LEVELT W. J. M., 1982, Linearization in describing spatial networks, w: S. Peters, E. Saarinen (red.), *Processes, beliefs and questions*, Dordrecht: Reidel.
- LEVELT W. J. M., 1983, Monitoring and self-repair in speech, *Cognition* 33, s. 41–103.
- LEVELT W. J. M., 1989, *Speaking: From intention to articulation*, Cambridge MA: MIT Press.
- MARQUES DE SÁ J. P., 2007, *Applied Statistics Using SPSS, STATISTICA, MATLAB and R*, Berlin–Heidelberg: Springer Verlag.
- MONTGOMERY D. C., RUNGER G. C., 2003, *Applied Statistics and Probability for Engineers*, Hoboken, NJ: John Wiley and Sons.
- PETT M. A., 1997, *Nonparametric Statistics for Health Care Research*, Thousand Oaks, CA: Sage.

- POSTMA A., KOLK H., 1992, The effects of noise masking and required accuracy on speech errors disfluencies and self-repairs, *Journal of Speech and Hearing Research* 35, s. 37–544.
- POULISSE N., 1993, A theoretical account of lexical communication strategies, w: R. Schreuder i B. Weltens (red.), *The bilingual lexicon*, Amsterdam: Benjamins, s. 157–189.
- THODE H. C., 2002, *Testing for normality*, New York: Marcel Dekker.
- VAN HEST G. W. C. M., 1996, *Self-repair in L1 and L2 production*, Tilburg: University Press.
- VAN DE WIEL M. A., 2004, Exact null distributions of quadratic distribution-free statistics for two-way classification, *Journal of Statistical Planning and Inference* 120, s. 29–40.
- VERHOEVEN L. T., 1989, Monitoring in children's second language speech, *Second Language Research* 5, s. 141–155.
- WIESE R., 1984, *Psycholinguistische Aspekte der Sprachproduktion: Sprechverhalten und Verbalisierungsprozesse*, Düsseldorf: Universität Bielefeld.
- ZHANG J., YUEHUA W., 2005, Likelihood-ratio tests for normality, *Computational Statistics and Data Analysis* 49, s. 709–721.

The Impact of the Cognitive Complexity of a Task on Self-Repairs

(s u m m a r y)

This paper investigates the influence of the cognitive complexity of a certain task type on the distribution of different categories of error self-repairs and appropriacy repairs. A recorded speech sample, in the Croatian language, lasting for approximately eight hours has been transcribed on a speech sample of 101 students at the Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture in Split. The classification of self-repairs is based on Levelt's model of speech production, as the empirically best supported theory of monolingual speech processing. The students have been individually tested by performing five speech tasks and their speech has been recorded. The tasks included: a) narration of the chronological order of events on the example of a cartoon, b) room description, c) repeated room description with different furniture arrangement, d) semantically unrelated utterance formulation based on pictures, and e) story telling based on a sequence of pictures. The retelling of the chronological order of events resulted in a higher frequency of syntactic and morphological error repairs compared to other tasks, whereas the frequency of lexical and phonological error repairs was not influenced by the task type. Furthermore, different information repairs occurred more frequently in the cartoon retelling task, compared to the description of rooms and the formulation of semantically unrelated utterances.