



UDK 811.163.42'271.14

Mirjana Matea Kovač

Univerza v Splitu

Damir Horga

Univerza v Zagrebu, Filozofska fakulteta

GOVORNE POGREŠKE STUDENATA TEHNIČKIH STUDIJA

Prispevek obravnava distribucijo in pogostnost govorjenih napak v hrvaščini pri študentih tehniških ved. Analiziran je zvočni zapis govora sto enega študenta elektrotehniške in strojne fakultete ter študentov ladjedelništva v Splitu; govor je bil dolg sedem ur in sedeminpetdeset minut. Razvrstitev napak je narejena po modelu W. J. M. Levelta, ki je dosedaj empirično potrjeno najboljši model za enojezično procesiranje govora.

This paper investigates the distribution and frequency of occurrence of speech errors in the Croatian language among the students of technical studies. A recorded speech sample lasting for 7 hours and 57 minutes has been analyzed on a corpus of 101 students at the Faculty of Electrical engineering, Mechanical engineering and Naval architecture in Split. The classification of speech errors is based on Levelt's model of speech production, as the empirically best supported theory of monolingual speech processing.

Ključne besede: modeli govorne proizvodnje, samonadgledavanje govora, disfluentnosti, govorne pogreške, sintaktičke pogreške

Key words: models of speech production, monitoring, disfluencies, speech errors, syntactic errors

1 Uvod

Govorna proizvodnja je vremenski kontinuiran proces u kojem govornik raspoređuje svoje vrijeme na periode planiranja sadržaja, jezične i artikulacijske strukture poruke i trenutke kada realizira planirano. Stvaranje izričaja je složen, kontinuiran i dinamičan proces tijekom kojeg pojedine komponente u mehanizmu govorne proizvodnje mogu zakazati i tako nastaju pogreške koje predstavljaju semantičku buku. Proizvodnja govora uključuje četiri osnovna procesa koji se odvijaju sljedećim redoslijedom: a) konceptualizaciju, odnosno planiranje sadržaja izričaja; b) formulaciju, koja uključuje gramatičko, leksičko i fonološko kodiranje izričaja; c) artikulaciju, koja predstavlja realizaciju govornih pokreta; te d) samonadgledavanje ili monitoring, koji podrazumijeva provjeravanje točnosti ili prikladnosti proizvedenog izričaja. Dok planiranje izričaja u proizvodnji materinskog jezika zahtijeva pojačanu svjesnu pažnju govornika, oblikovanje i artikulacija su automatizirani procesi koji mogu raditi paralelno bez svjesnog napora govornika. Međutim, unatoč automatiziranoj prirodi materinskog jezika, govornici ne proizvode savršen govor, već na različite načine oklijevaju, zastajkuju i ponavljaju dijelove izričaja ili griješe (Horga, 2008). Govorne pogreške su odstupanja od govornikovih komunikacijskih namjera i važan su izvor podataka za razumijevanje složenih mehanizama govorne proizvodnje. Rezultati istraživanja u materinskom (npr. Fromkin, 1973, Dell i Reich, 1981, Stemberger, 1985, Levelt, 1989, van Hest, 1996,

Erdeljac, 2005) te u stranom jeziku (npr. Poullisse, 1999, van Hest, 1996) ukazuju da su pogreške u pristupu leksemima u mentalnom leksikonu vrlo česte. Pogreške mogu zahvatiti različite mehanizme u hijerarhiji govorne proizvodnje. Neidealno funkcioniranje može se pojaviti kao posljedica nesavršenih programa govorne proizvodnje ili zato što realizacija programa u nekim trenucima može zakazati. S druge strane, u stranom jeziku pogreške su često rezultat nedovoljnog poznavanja jezika ili semantičke buke u komunikacijskom procesu (Jaeger, 2005). Dell (1986) smatra da pogrešna aktivacija određenih čvorova uzrokuje pojavu govornih pogrešaka. On tvrdi da realizacija određene jedinice ovisi o stupnju njezine aktivacije, ali i o aktivaciji drugih jedinica koje predstavljaju asocijativno organiziranu mrežu. To znači da jedinica, koja je u postupku realizacije, u određenom trenutku mora biti deaktivirana kako bi ispraznila mjesto i ustupila ga drugoj jedinici.


Nakatani i Hirschberg (1994) navode da 10 % izričaja u materinskom jeziku uključuje neku vrstu ispravka, a Nooteboom (1980) zaključuje da 50 % pogrešaka ostaje neispravljeno. Postoji više razloga zbog kojih govornik ne ispravlja pogrešku. Ponekad mehanizam monitoringa ne reagira na pogrešku zato što je u određenom trenutku nije registrirao ili zato što je govor dovoljno redundantan, tako da sugovornik može pravilno interpretirati poruku i bez ispravka. Međutim, većina pogrešaka se ipak ispravlja bez intervencije sugovornika, što upućuje na postojanje sustava za nadgledavanje govora i povratnih sprega. Njihov zadatak je kontroliranje učinkovitosti govorne komunikacije, te po potrebi ispravljanje i doradivanje govorne obavijesti. Posljednjih nekoliko desetljeća raste zanimanje za jezičnu proizvodnju, a rezultiralo je psiholingvističkim modelima pomoću kojih se pokušavaju objasniti mehanizmi u službi proizvodnje govora, govorne pogreške, samoispravljanja, te različiti oblici disfluentnosti.

Cilj je ovog rada utvrditi zastupljenost pojedine kategorije pogrešaka u njihovom ukupnom broju, te ispitati kako kognitivna složenost govornog zadatka utječe na učestalosti pojavljivanja pojedinih kategorija pogrešaka kod populacije studenata tehničkih studija. Rad započinje opisom Leveltovog modela govorne proizvodnje i teorije perceptivne petlje kojom se objašnjava način otkrivanja pogrešaka ili neprikladnosti. Zatim se izlaže klasifikacija pogrešaka koja se temelji na opisanom modelu govorne proizvodnje, kao empirijski najprihvaćenijem modelu za monolingvalno procesiranje. U nastavku rada iznose se primijenjeni metodološki postupci te se na temelju rezultata analize govornog uzorka donose odgovarajući zaključci.

2 Leveltov model govorne proizvodnje

Literatura bilježi brojne pokušaje stvaranja razumljivog psiholingvističkog modela govorne proizvodnje, no najprihvaćeniji i najrasprostranjeniji model u istraživanjima proizvodnje govora je Leveltov model (Levelt 1989, 1993, 1995, 1999), slika 1. Levelt smatra da je proizvodnja govora modularna i može se opisati kao samostalno funkcioniranje niza relativno autonomnih procesnih sastavnica. To su: konceptualizator, formulator, artikulatork i akustičko-fonetski procesor, te sustav za razumijevanje govora (engl. *parser*). Postoje tri spremišta znanja: leksikon, slogovnik koji sadržava fonološku informaciju i spremište koje sadržava modele diskursa, situacijsko i enciklopedijsko

znanje. Osnovni mehanizmi procesiranja govora funkcioniraju na vrlo jednostavan način: ljudi proizvode govor tako što najprije konceptualiziraju obavijest, formuliraju je jezični prikaz i konačno ga artikuliraju. Akustičko-fonetski procesor prvi evaluira govor, nakon čega prolazi kroz lingvističko dekodiranje u sustavu za razumijevanje i konačno ga modul za konceptualizaciju interpretira. Model vrlo precizno specificira ulogu leksikona¹ i postupke monitoringa u odnosu na procesne komponente i eksplicitno opisuje usmjerene putove između modula, prikazujući njihovu suradnju u proizvodnji zajedničkog i konačnog proizvoda, govora.



Slika 1: Leveltov model govorne proizvodnje (u: Erdeljac

Slika 1: Leveltov model govorne proizvodnje (u: Erdeljac, 2009)

U Leveltovom modelu su procesne komponente „specijalisti» u određenim funkcijama koje moraju izvršiti, što znači da one ne dijele procesne funkcije. Sastavnica ili modul će početi procesiranje jedino ako dobije karakterističan ulaz. Levelt pretpostavlja da je procesiranje inkrementalno, to jest da procesor koji slijedi može započeti s radom i prije negoli je dovršen izlazni podatak iz prethodnog procesora. Nakon što konceptualizator proslijedi dio predverbalne poruke formulatoru, on počinje raditi na idućem dijelu poruke, neovisno o tome da li se prethodni dio poruke još uvijek procesira. Posljedično, artikulacija izričaja može započeti puno ranije nego što je govornik završio planiranje cijele poruke. Svi procesori mogu raditi paralelno, ali ne istovremeno na istom dijelu izričaja koji se stvara, već na drugim njegovim dijelovima (Erdeljac, 2009). Ovo je

+ Prizivanje leksičkih jedinica iz mentalnog leksikona je način na koji govornik željenu obavijest oblikuje u riječi (Levelt, 1989). Mentalni leksikon je skladište znanja o riječima iz vlastitog jezika, a govornik na temelju dijelova konceptualne strukture priziva prikladne leksičke jedinice kako bi ispravno prenio komunikacijsku namjeru.

moguće jer je većina mehanizama u proizvodnji materinskog jezika, poglavito u fazi kodiranja, potpuno automatizirana. Inkrementalna, paralelna i automatizirana priroda procesiranja može objasniti veliku brzinu proizvodnje govora.

Slika 1 prikazuje osnovne komponente procesiranja uključene u proizvodnju govora. Prva komponenta, konceptualizator, generira poruku kroz: a) makroplaniranje koje uključuje elaboraciju komunikacijske namjere², konceptualni i propozicijski sadržaj poruke te rezultira makroplanom, što Levelt (1989) naziva namjerama govornih činova (engl. *speech-act intentions*); b) mikroplaniranje koje oblikuje semantičke prikaze povezane sa sadržajem poruke, i na taj način makroplanu daje određenu strukturu, što rezultira predverbalnim planom. Predverbalni plan je izlazni podatak konceptualizatora i istovremeno ulazni podatak idućeg modula za procesiranje, formulatora, koji ima zadatak prevesti konceptualnu strukturu u lingvističku, odnosno izabrati leksičke jedinice te izvršiti gramatičko i fonološko kodiranje. Formulator pristupa leksikonu i priziva odgovarajući leksički unos koji sačinjava:

- a) lema³, koja određuje značenje i sintaksu leksičkoga unosa;
- b) leksem, koji nosi informaciju o morfofonološkom obliku leksičkog unosa.

Osnovni postupak koji se događa u formulatoru je aktivacija lema. Govornik će prizvati lemu čije značenje najbolje odgovara semantičkoj informaciji koju nosi odgovarajući dio predverbalnog plana. Levelt (1989) pretpostavlja da se odabirom leme aktivira njezina sintaksa koja postaje okidač za procese sintaktičke izgradnje. Gramatički procesor pristupa lemapu u leksikonu, oblikuje sintaktičke sastavnice (imenska fraza, glagolska fraza, itd.) koje potom linearno organizira. Navedeni međuproizvod se ne sprema u radnoj memoriji nego u odvojenom sintaktičkom međuspremniku (Levelt, 1989). Fonološki procesor pristupa formalnom dijelu leksikona te pridaje morfološki i fonološki oblik izričaju, uključujući prozodijske osobine. Konačni rezultat fonološkog kodiranja je fonetski ili artikulacijski plan ili tzv. „unutrašnji govor» (engl. *internal speech*). Levelt (1989) pretpostavlja postojanje artikulacijskog međuspremnika za privremeno pohranjivanje fonetskog plana prije artikulacije. Uz pomoć artikulacijskih pokreta slogovnika artikulatur „unutrašnji govor» prevodi u „otkriveni govor» (engl. *overt speech*).

Sustav za razumijevanje govora ima funkciju otkrivanja pogreške nakon njene vanjske manifestacije, a govorniku omogućava kontrolu unutrašnjeg govora koji se nalazi u radnoj memoriji (Levelt, 1989). Tako govornik može modificirati djelomično proizvedene izričaje, odbaciti neartikulirane izričaje, te ignorirati pogrešku i namjerno se ne ispraviti zato što pogrešku ne smatra potencijalnim problemom za slušatelja. U Leveltovom modelu su pažnja i radna memorija najvažnije u fazi konceptualizacije i kod monitoringa, a manje važne u fazi formulacije i artikulacije.

Message construction is controlled processing, and so is monitoring; self-corrections are hardly ever made without a touch of awareness. The speaker can attend to his or her own

² Unutar Leveltovog modela namjera (engl. *intention*) se interpretira kao »willingness to execute a speech plan« (Levelt 1989: 59) Levelt ne objašnjava odakle namjera dolazi. Ograničava svoju diskusiju na komunikacijske namjere, koje se odnose na govorne činiove.

³ Lema se koristi kao tehnički termin samo za sintaktička obilježja riječi, koje su određene sintaktički i semantički, ali ne i fonološki (Erdeljac 2009).

internal speech. The limited-capacity resource in conceptualizing and monitoring is Working Memory (Levelt, 1989:21).

Drugi model tumačenja mehanizama govorne proizvodnje je Dellova (1986) teorija širenja aktivacije koja objašnjava pristup leksemima u proizvodnji govora u stvarnom vremenu. Novina Dellovog (1986) modela je u tome što se leksikon, koji sadržava ne-produktivno znanje, promatra kao mreža međusobno povezanih jedinica, takozvanih čvorova, koji predstavljaju lingvističke jedinice kao što su koncepti, riječi, morfemi, fonemi, fonemska obilježja, slogovi i slogovne sastavnice. On pretpostavlja da se u leksikonu konceptualni čvorovi povezuju uz riječne čvorove koji definiraju riječi i povezani su s morfemskim čvorovima, koji predstavljaju određene morfeme. Nadalje, postoji povezanost između morfemskih i fonemskih čvorova koji određuju foneme, i konačno fonemskih čvorova koji su povezani s čvorovima za fonemska obilježja. Mehanizam koji je odgovoran za proizvodnju rečenice je proces širenja aktivacije. Kod procesiranja bez pogrešaka pristupa se čvoru tražene kategorije (npr. čvoru riječi), to jest čvoru koji ima najveći stupanj aktivacije ili pobuđenosti. Aktivacija se širi od čvorova semantičkih obilježja do odgovarajućih čvorova riječi ili leme, koji potom prosljeđuju aktivaciju na fonemske čvorove. To znači da aktivacija „preskače» s jedne razine na drugu.

Priming produces increased subthreshold activity in a node. It spreads in parallel across nodes, with its strength being positively related to how well it matches the input. In the same fashion, priming spreads to the phonological nodes and, finally, to the lexical nodes. At each level, priming strength is a function of the match to the input from the preceding level. Although several nodes may be primed at once, only the node that is primed to a higher degree than all the others becomes activated (Shoaf i Pitt, 2002:1).

Model pretpostavlja postojanje inhibitornih veza između čvorova na istoj razini procesiranja te se na taj način osigurava ispravan odabir čvorova. Dell (1986) pretpostavlja da se aktivacija može širiti u oba smjera. To znači da će pogrešno odabrani i aktivirani čvor početi širiti aktivaciju u suprotnom smjeru, to jest „odozdo prema gore». U slučaju pogrešno odabrane riječi aktivacija će se širiti od razine čvorova koji predstavljaju riječi do konceptualnih čvorova. Pretpostavlja se da ovaj isti mehanizam povratne sprege djeluje u percepciji govora i čini monitor inherentnim svojstvom procesa percepcije i proizvodnje govora.

3 Samonadgledavanje govora

Većina pogrešaka se ispravlja bez intervencije sugovornika, što upućuje na postojanje sustava za nadgledavanje govora i povratnih sprege. Leveltovom (1983, 1989) teorijom perceptivne petlje (engl. *perceptual loop theory*) objašnjava se otkrivanje pogrešnog izlaznog podatka. Istraživanja govornih pogrešaka u materinskom jeziku potvrđuju superiornost ove teorije nad drugima (npr. Blackmer i Mitton, 1991, Nootboom, 2005). Teorije govorne proizvodnje u stranom jeziku (npr. Kormos, 2006) su je također prihvatile i smatraju da ne postoje kvalitativno drugačiji mehanizmi monitoringa u stranom jeziku. Model uključuje tri petlje za provjeravanje izričaja. To su direktni


kanali povratne sprege koji se vraćaju prema monitoru koji provjerava konačni proizvod procesa proizvodnje. Prva ili konceptualna petlja (Levelt, 1989, Blackmer i Mitton, 1991) provjerava predverbalni plan s prvobitnom namjerom govornika prije nego se proslijedi formulatoru na daljnju obradu. Njezin zadatak je nadgledavanje prikladnosti izričaja, to jest otkrivanje konceptualnih pogrešaka. Blackmer i Mitton (1991) te Van Hest (1996) zaključuju da se konceptualne pogreške ispravljaju značajno sporije nego leksičke i fonološke. Pogrešan koncept je teže odbaciti i zamijeniti novim te je zbog toga više vremena potrebno kako bi se govornik ispravio (Postma, 2000).

Druga ili unutrašnja petlja je zadužena za monitoring fonetskog plana ili tzv. unutrašnjeg govora prije artikulacije, što se naziva prikriveni monitoring (engl. *covert monitoring*) (Wheeldon i Levelt, 1995). Ona omogućava govorniku otkriti pogrešku prije vanjske manifestacije. Levelt (1989) tvrdi da postupak određivanja rečenične strukture (engl. *parsing*) traje otprilike 150-200 ms nakon što je generiran fonetski plan, a pogreška će biti uočena oko 150 ms nakon pojave na razini fonetskog plana. Artikulator će realizirati govorni plan nakon 200-250 ms. Na taj mu način preostaje oko 100 ms za otkrivanje i ispravak prije nego što dođe do vanjske realizacije. Čak je i više vremena dostupno ukoliko je fonetski plan privremeno pohranjen dok čeka na artikulacijsku realizaciju (Postma, 2000). Ključno je pitanje veličine međuspremnika i brzine artikulacije. Blackmer i Mitton (1991) smatraju da je posebni potprogram ponovnog započinjanja (engl. *restart*) lociran između artikulacijskog međuspremnika i artikulacijske razine. Postma i Kolk (1993) ga nazivaju monitorom proračuna vremena između međuspremnika i artikulacije (engl. *buffer-articulation timing monitor*) koji je osjetljiv na vremensku organizaciju novog materijala koji treba artikulirati. Ako novi ulazni podatak nije dostupan u trenutku kada je artikulator završio s realizacijom određenog govornog programa, a započeti izričaj nije dovršen, tada se zasigurno pojavila pogreška. Autori pretpostavljaju da artikulator posjeduje autonomnu sposobnost ponovnog započinjanja te će realizirati stari program po drugi put ako pravovremeno ne dobije novi ulazni podatak. To se najčešće događa pri velikim brzinama govora koje onemogućuju privremeno pohranjivanje i tako se povećava mogućnost pogrešnog vremenskog proračuna, što rezultira ponavljanjima kraćih govornih odsječaka. Otkrivanje pogreške u trenutku njezine vanjske manifestacije ovisi o dostupnosti i kapacitetu artikulacijskog međuspremnika. Veća brzina govora smanjuje privremeno pohranjivanje (Levelt, 1989, Blackmer i Mitton, 1991, Van Hest, 1996).

Proizvedeni se izričaj provjerava i nakon artikulacije, što sačinjava vanjsku petlju monitoringa koja uključuje akustičko-fonetski procesor. Monitor se prema Leveltu nalazi u konceptualizatoru, ali dobiva informacije iz odvojenog sustava za razumijevanje govora, tzv. *parser*a, koji je povezan s mentalnim leksikonom. Monitor će izdati alarmni signal ako zapazi pogrešku ili neprikladnost u bilo kojoj od faza procesiranja, te će se isti mehanizmi za proizvodnju govora pokrenuti po drugi put. Kako bi se izbjegla reduplikacija znanja, Levelt smatra da se isti leksikon koristi za proizvodnju i percepciju vlastitog govora, te se isti sustav za razumijevanje koristi za praćenje vlastitog i sugovornikovog govora (preko akustičko-fonetskog modula).

4 Govorne pogreške

Levelt (1983) razlikuje leksičke, sintaktičke i fonetske 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. U Leveltovoju teoriji (1989) se sadržajne i funkcionalne riječi, te kolokacije i idiomi smatraju leksičkim ulazima (engl. *lexical entries*), slika 2. Pogreške derivacijske morfologije, npr. *different* umjesto *difference* također pripadaju kategoriji leksičkih pogrešaka, zato što derivacije u Leveltovom (1989) modelu leksikona predstavljaju različite leksičke ulaze.



Slika 2: Leveltov (1989) prikaz leksičkog ulaza

Leksičke pogreške su »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. Sintaktička pogreška uključuje sintaktičku konstrukciju koja vodi do „mrtve točke» nakon koje govornik ne može nastaviti izričaj (Levelt, 1983:54). Nažalost, Levelt nije dao preciznu definiciju fonetskih pogrešaka te ne objašnjava kako se definiraju morfološke pogreške.

Horga (1997) razlikuje pogreške kongruencije, pogreške u otkrivanju izgovornog programa, izbor pogrešne riječi, te sintaktičko-propozicijske pogreške.

U tablici 1 iznesene su kategorije pogrešaka i samoispravljanja u govornoj proizvodnji s primjerima koji su preuzeti od Blackmer i Mitton (1991), Cutler (1983), De Smedt i Kempen (1987), Levelt (1983) i Van Wijk i Kempen (1987) u: Postma, 2000.

Tablica 1: Kategorije pogrešaka i samoispravljanja u govornoj proizvodnji

Primjer	Vrsta pogreške	Vrsta samoispravljanja	Osnovne aktivnosti kod samoispravljanja
<i>'We start in the middle with – in the middle of the paper with a blue disc.'</i>	Konceptualna pogreška	Ispravak nepreciznosti preformulacijom.	Značajnije vraćanje unatrag i preispitivanje koje se temelji na sintaktičkoj strukturi izričaja i vodi do gramatički ispravno oblikovanog nastavka. Pronominalizacija je moguća u ispravku.
<i>'John comes – uh-likes to come to the party.'</i>	Sintaktička »mrtva točka«	Sintaktičko restrukturiranje/preformulacija.	Vraćanje unatrag i preformulacija koja se temelji na sintaktičkoj strukturi.
<i>'Left of purple is-uh – of white is purple.'</i>	Leksička pogreška	Zamjena leme	Odsječak zahvaćen vraćanjem unatrag je morfofonološki uvjetovan. Zamjenjuje se pogrešna lema, a ostale sastavnice su nepromijenjene.
<i>'A unut-unit from the yellow dot.'</i>	Fonemska pogreška	Ispravljanje fonemske pogreške.	Manje vraćanje unatrag i ponovno započinjanje.
<i>'...from my PROsodic-proSODIC colleagues.'</i>	Prozodijska pogreška	Ispravak suprasegmentalne pogreške.	Vraćanje unatrag i ponovno započinjanje, uglavnom zbog pogreške naglaska leksičke jedinice uslijed pragmatičkih ili semantičkih razloga.
<i>'willfiddily-fully'</i>	Morfemska pogreška	Ispravak »u letu« (nema jasnog prekida).	Zamjena bez ponovnog započinjanja.
<i>'... ideals by-uh-by va-voting for the Meech lake accord.'</i>	Fonemska pogreška (prethodi joj oklijevanje)	Ispravak »u letu« (nema jasnog prekida).	Manje vraćanje unatrag i ponovno započinjanje.
<i>'to a-uh-stapler'</i>	Nepoznato	Prikriveni ispravak	Odgadanje.
<i>'to-to the right'</i>	Nepoznato	Prikriveni ispravak	Ponovno započinjanje.

5 Cilj istraživanja i metodološki postupci

Cilj je ovog rada utvrditi raspodjelu i učestalost kategorija pogrešaka u materinskom jeziku, te ispitati kako kognitivna kompleksnost zadatka utječe na njihovo pojavljivanje. Ispitivanje je provedeno na uzorku od 101-og ispitanika, studenata prve godine Fakulteta elektrotehnike, strojarstva i brodogradnje u Splitu. Pogreške, kao varijable govorne fluentnosti, ispitane su na različitim testovima govornog opisivanja: prepričavanje

kronološkog redoslijeda radnje animiranog filma, opisi prostorija, oblikovanje sadržajno nepovezanih izričaja na temelju crteža i oblikovanje priče.

U prvom zadatku su ispitanici pogledali crtani film *Johnny Bravo* na engleskom jeziku. Navedeni crtani film odabran je zbog pretpostavke da je relativno nepoznat ispitanicima i da sadržaj predstavlja značajniji kognitivni napor u smislu organizacije za diskurs. Nakon gledanja crtanog filma u trajanju od šest minuta, svaki ispitanik je prepričao 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) uključivao je opisivanje slike prostorno-statičnih konstelacija i njihovih međusobnih odnosa. Ispitanik je opisao izgled prostorije u kojoj je bilo šest komada namještaja, tako da je sugovornik na temelju opisa mogao rekonstruirati njezin izgled. Treći zadatak je gotovo identičan drugom, osim što je namještaj bio drugačije razmješten.

U četvrtom zadatku je ispitanik oblikovao dvadeset sadržajno nepovezanih izričaja na temelju slikovnih prikaza. Tražene riječi su pripadale 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 je imao jednu minutu za pripremu.

Peti zadatak (oblikovanje priče) je kombinacija prvog i četvrtog. Ispitanik je na temelju prikaza pet sadržajno nepovezanih crteža oblikovao sadržaj priče, tako da niti jedan prikaz sa crteža nije smio biti izostavljen. Kao ni u prethodnim zadacima, sintaktički okvir nije bio zadan i ispitanici nisu bili ograničeni vremenom.

Varijable fluentnosti govora su zabilježene na temelju individualnog audio-snimanja govornika. Vremenski parametri su određeni mjerenjem govornih uzoraka u programu za akustičku analizu govora *Audicity*. Pogreške su identificirane i analizirane u skladu s Leveltovom (1983:44) strukturom ispravka koja uključuje tri dijela:

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

Prvi dio '*Go from left again to*' čini prvobitni izričaj (engl. *original utterance*) i sadrži problematično mjesto ili pogrešku (engl. *reparandum*) koju treba ispraviti ('*left*'). Pogreškom mogu biti zahvaćeni kraći i duži govorni odsjeci, počevši od jednog glasnika do cjeline teksta. Govornik se može prekinuti usred i nakon pogrešne riječi, te se također može pojaviti i odgođeni prekid. Prekid je ponekad popraćen određenim oblicima disfluentnosti (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. U nekim slučajevima se pogreške ne ispravljaju, a povremeno rezultiraju novim pogreškama. Nizanje pogrešaka nije neuobičajena pojava (Levelt, 1983), te je u ovom radu svaka pogreška u nizu uzastopnih pogreška posebno zabilježena.

a) Sintaktička pogreška se definira kao započeta sintaktička konstrukcija koja vodi do „mrtve točke“ i govornik je ne uspijeva dovršiti. Osim pogrešno započetog izričaja (engl. *false start*) koji se prekida (1), ova kategorija uključuje i pogrešan redoslijed riječi te izričaj čiji je propozicijski sadržaj nejasan.

(1) hm ipak je Johnny Bravo uspio pobjeći ali ga je me- ali je medvjed krenuo za njim.

b) Morfološka ili pogreška kongruencije (Horga, 1997) uključuje pogreške u rodu, broju, padežu ili govornik tvori morfološki oblik koji nije u skladu s jezičnom normom (2). Javlja se kada govornik treba odabrati i izgovoriti morfološki oblik neke riječi koji je ovisan o riječi koja će u govoru biti ostvarena kasnije, a govornik je u svom govornom programu još nije odabrao.

(2) Tražio je po hm cijelom š- cijeloj šumi no nije je mogao pronaći.

c) Leksička pogreška nastaje kao posljedica prizivanja pogrešne leme (3).

(3) hm moj brat voli jesti zel- žute banane.

d) Fonološke pogreške su pogreške u ostvarivanju izgovornog programa (Horga, 1997) i uključuju slučajne zamjene fonema (4) te izgovorne nespretnosti.

(4) Zatim ga je medvjed hm hm htio pojesti jer je ogladnio jer se- šest mjeseci ništa nije jeo.

U tablici 2 je prikazana klasifikacija pogrešaka primijenjena u ovom radu. U nastavku slijede rezultati analize, pri čemu se koriste odgovarajući kodovi 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.

Tablica 2: *Klasifikacija pogrešaka u ovom radu*

Vrsta pogreške	Definicija	Primjer
Pogreške Leksička pogreška Morfološka pogreška Sintaktička pogreška Fonološka pogreška	Pogrešno aktivirana lema (Levelt, 1983). Pogreška kongruencija. 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). Započeta sintaktička konstrukcija koja vodi do „mrtve točke» i koju govornik ispravlja ili ne ispravlja. Ponekad je sintaksa izričaja potpuno konfuzna te govornik prekida izričaj i ponovno ga započinje (eng. <i>restart</i>). U ovu kategoriju je također uključen pogrešan redoslijed riječi i izričaji nerazumljivog sadržaja. Pogreška u ostvarivanju izgovornog programa i izgovorne nespretnosti (Horga, 1997).	Hm moj brat voli jesti <u>zel</u> - žute banane. Tražio je po hm cijelom š- cijeloj šumi no nije je mogao pronaći. hm ipak je Johnny Bravo uspio pobjeći <u>ali ga je me</u> - ali je medvjed krenuo za njim. Zatim ga je medvjed hm hm htio pojesti jer je ogladnio jer <u>se</u> - šest mjeseci ništa nije jeo.

6 Rezultati distribucije pogrešaka

U svim zadacima su ispitanici izgovorili ukupno 52 795 riječi, od kojih se gotovo polovina odnosi na FILM – prepričavanje crtanog filma, tablica 3. Ako se podaci razmatraju u vremenskoj domeni, vidljivo je se da su ispitanici govorili gotovo punih 8 sati, od kojih se približno 3 odnose na prepričavanje crtanog filma. Također, u tablici 3 izneseni su i podaci o trajanju govora u minutama i sekundama za svaki od zadataka, te skupno u svim zadacima.

U tablici 4 predočena je distribucija pogrešaka koja se odnosi na sve zadatke skupno. Ukupno je zabilježena 941 pogreška. Približno polovina svih pogrešaka su sintaktičke (50,9 %), dok leksičke obuhvaćaju oko $\frac{1}{4}$ (25,6 %) svih pogrešaka. Tek svaka dvadeseta pogreška je fonološke prirode (5,2 %).

	FILM	SOBA1	SOBA2	IZORE	STRIP	Svi zadaci
<i>r</i>	24 514	5 300	5 477	11 422	6 082	52 795
<i>t_h</i> [sati]	2.947	0.775	0.726	2.525	0.974	7.947
<i>t_m</i> [min]	176.837	46.516	43.548	151.475	58.465	476.842
<i>t_s</i> [s]	10 610.2	2 791.0	2 612.9	9 088.5	3 507.9	28 610.5

Tablica 3: Broj riječi i trajanje govora

Pogreške Svi zadaci	<i>N_E</i>	<i>p_E</i> (%)
<i>E_S</i>	479	50.904
<i>E_L</i>	241	25.611
<i>E_M</i>	172	18.278
<i>E_F</i>	49	5.207
<i>E</i>	941	100

E_S – sintaktička pogreška, *E_L* – leksička pogreška, *E_M* – morfološka pogreška, *E_F* – fonološka pogreška, *E* – pogreška općenito, *N_E* – ukupni broj pogrešaka, *p_E* – postotni udjel pojedine kategorije pogrešaka

Tablica 4: Distribucija pogrešaka skupno za sve zadatke

Ako se raspodjela pogrešaka analizira odvojeno po zadacima, tablice 5–9, može se zaključiti da je u svim zadacima sintaktička pogreška najzastupljenija kategorija. Nakon sintaktičkih pogrešaka najzastupljenije su leksičke pogreške u svim zadacima, osim u STRIP-u, u kojem se može primijetiti relativno visoki udjel morfoloških pogrešaka (nešto manje od $\frac{1}{3}$), tablica 9. U zadatku STRIP je ispitanik trebao na temelju slikovnih

prikaza oblikovati sadržaj priče. On učestalije odabire pogrešan morfološki nastavak zato što leksičku jedinicu koja slijedi još nije odabrao u svom govornom programu. U svakom zadatku se najrjeđe pojavljuju fonološke pogreške. Iz rezultata proizlazi da je visoki postotni udjel sintaktičkih pogrešaka zabilježen kod odabranog uzorka koji se odnosi na populaciju studenata tehničkog fakulteta. Ispitanicima je prioritet prenijeti sugovorniku obavijest i vrlo često ne vode računa o načinu na koji se izražavaju. Učestali oblik sintaktičkih pogrešaka su prekidi započetog izričaja i posljedično preformulacija ili ponovno započinjanje (engl. *restart*) sintaktičkom nadopunom. Fox Tree (1995) ponovna započinjanja izričaja definira kao govorne disfluentnosti koje se javljaju kao popratna pojava govornog planiranja i pokušaja da se uskladi govorni izraz s ostalim kognitivnim procesima. Poteškoće se mogu pojaviti na bilo kojoj razini procesa proizvodnje govora, odnosno za vrijeme planiranja poruke, leksičkog prizivanja i gramatičkog kodiranja, te konačno artikulacije govornog plana. Postoji stajalište da je kognitivni napor uzrok disfluentnostima, a potvrđen je u istraživanjima u kojima se disfluentnosti češće pojavljuju ispred dužih izričaja (Shriberg, 1994) ili ako je tema nepoznata (Bortfeld i sur., 2001).

Pogreške FILM	N_E	p_E (%)
E_S	266	60.045
E_L	84	18.962
E_M	79	17.833
E_F	14	3.160
E	443	100

E_S – sintaktička pogreška, E_L – leksička pogreška, E_M – morfološka pogreška, E_F – fonološka pogreška, E – pogreška općenito, N_E – ukupni broj pogrešaka, p_E – postotni udjel pojedine kategorije pogrešaka

Tablica 5: Raspodjela pogrešaka u FILM-u

Pogreške SOBA1	N_E	p_E (%)
E_S	48	45.283
E_L	40	37.736
E_M	11	10.377
E_F	7	6.604
E	106	100

E_S – sintaktička pogreška, E_L – leksička pogreška, E_M – morfološka pogreška, E_F – fonološka pogreška, E – pogreška općenito, N_E – ukupni broj pogrešaka, p_E – postotni udjel pojedine kategorije pogrešaka

Tablica 6: Raspodjela pogrešaka u SOBA1

Pogreške SOBA2	N_E	p_E (%)
E_S	49	49.495
E_L	38	38.384
E_M	7	7.071
E_F	5	5.051
E	99	100

E_S – sintaktička pogreška, E_L – leksička pogreška, E_M – morfološka pogreška, E_F – fonološka pogreška, E – pogreška općenito, N_E – ukupni broj pogrešaka, p_E – postotni udjel pojedine kategorije pogrešaka

Tablica 7: Raspodjela pogrešaka u SOBA2

Pogreške IZORE	N_E	p_E (%)
E_S	73	40.110
E_L	55	30.220
E_M	40	21.978
E_F	14	7.692
E	182	100

E_S – sintaktička pogreška, E_L – leksička pogreška, E_M – morfološka pogreška, E_F – fonološka pogreška, E – pogreška općenito, N_E – ukupni broj pogrešaka, p_E – postotni udjel pojedine kategorije pogrešaka

Tablica 8: Raspodjela pogrešaka u IZORE-u

Pogreške STRIP	N_E	p_E (%)
E_S	43	38.739
E_L	24	21.622
E_M	35	31.532
E_F	9	8.108
E	111	100

E_S – sintaktička pogreška, E_L – leksička pogreška, E_M – morfološka pogreška, E_F – fonološka pogreška, E – pogreška općenito, N_E – ukupni broj pogrešaka, p_E – postotni udjel pojedine kategorije pogrešaka

Tablica 9: Raspodjela pogrešaka u STRIP-u

7 Rezultati ispitivanja utjecaja vrste zadatka na određenu kategoriju pogrešaka

U ovom poglavlju se razmatra kako kognitivna složenost pojedinog zadatka utječe na određenu kategoriju pogrešaka, odnosno ispituje se postoje li statistički značajne razlike u učestalostima određene kategorije pogreške između različitih zadataka. 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 pogreške 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.

U tablici 10 prikazane su uzoračke vrijednosti i veličine vezane za učestalosti sintaktičkih pogrešaka na 100 riječi. Glavni razlog ovako detaljnog prikaza je potreba za dobrim poznavanjem uzoraka, kako bi se donijela odluka koje uzorke međusobno usporediti, ako se kao rezultat testiranja dobije da populacije iz kojih dolaze uzorci nisu identične.

Kako su u ovom radu istraživanja utjecaja kognitivne složenosti na pojavnost različitih kategorija pogrešaka 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.

U tablici 11 vidljivi su rezultati Shapiro-Wilkovog testa normalnosti za distribucije učestalosti sintaktičkih pogrešaka na 100 riječi koje pripadaju razmatranim zadacima. 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 i Yuehua, 2005, Keskin, 2006, Henderson, 2006, Coin, 2008). Može se primijetiti da sukladno ovom testu distribucije svih 5 populacija statistički značajno odstupaju od normalne distribucije. Stoga je odabran 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 i 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, što nije slučaj s obzirom na rezultat Shapiro-Wilkovog testa. Ako uvjeti za primjenu parametrijskih testova nisu ispunjeni, superiornost neparametrijskih testova nije sporna (Montgomery i Runger, 2003).

a) Sintaktičke pogreške

U tablici 12 prikazani su rezultati Friedmanovog testa za učestalosti sintaktičkih pogrešaka na 100 riječi. *P*-vrijednost Friedmanovog testa je manja od 0.0001, što znači da su dobivene statistički značajne razlike u učestalostima sintaktičkih pogrešaka između pojedinih zadataka.

E_S	<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
D₁	0	0	0	0	0
Q₁	0.427	0	0	0	0
Me	0.905	0	0	0	0
Q₃	1.488	1.697	1.266	1.070	1.637
D₉	2.273	2.660	2.859	2.046	2.119
$x_{\max}$	3.806	5.263	7.042	3.158	4.000
d	3.806	5.263	7.042	3.158	4.000
d_Q	1.061	1.697	1.266	1.070	1.637
$\bar{x}$	1.049	0.805	0.799	0.591	0.674
σ	0.906	1.308	1.438	0.875	0.985
σ^2	0.821	1.711	2.068	0.766	0.970
S_{$\bar{x}$}	0.090	0.130	0.143	0.087	0.098
V	86.37 %	162.52 %	179.98 %	147.92 %	146.10 %
α_3	0.963	1.634	1.989	1.378	1.097
α_4	0.692	2.190	3.924	0.907	0.064

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 10: Uzoračke vrijednosti i veličine za učestalosti sintaktičkih pogrešaka na 100 riječi

Shapiro-Wilk	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
W	0.9096	0.6705	0.6310	0.7198	0.6992
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 11: Shapiro-Wilkov test normalnosti za učestalosti sintaktičkih pogrešaka na 100 riječi

Friedman	n	df	F_r	p
	101	4	34.181	<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 12: *Friedmanov test za učestalosti sintaktičkih pogrešaka na 100 riječi*

Friedmanovim testom se došlo do zaključka da treba odbaciti nul-hipotezu o identičnosti populacija, ali taj test ne daje odgovor između kojih zadataka postoje statistički značajne razlike u učestalostima sintaktičkih pogrešaka. 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, tablica 10. Zaključno, preporučljivo je biti izbirljiv u odabiru parova za usporedbu (Marques de Sá, 2007).

Uzimajući u obzir da je u FILM-u već donji kvartil različit od nule, dok je u ostalim zadacima ne samo donji kvartil, nego i medijan jednak nuli, tablica 10, proveden je Dunnov test višestrukih usporedbi za učestalosti sintaktičkih pogrešaka na 100 riječi za kombinacije parova zadataka koje sadrže FILM. Drugim riječima, FILM se uspoređuje sa svakim od ostalih zadataka, tablica 13.

Dunn	Razlika u sumi rangova	Statistički značajna razlika
FILM – SOBA1	86	Da
FILM – SOBA2	78	Da
FILM – IZORE	99.5	Da
FILM – STRIP	84	Da

Tablica 13: *Dunnov test višestrukih usporedbi za učestalosti sintaktičkih pogrešaka na 100 riječi*

Kao što je vidljivo iz tablice 13, statistički značajna razlika postoji u učestalostima sintaktičkih pogrešaka u FILM-u u odnosu na sve ostale zadatke. Kod opisivanja strukture kronološkog događaja (FILM) uzastopni govorni činovi se organiziraju *on line*, a problemi u planiranju i izvedbi se rješavaju *ad hoc*. Prepričavanje radnje je kognitivno složen i zahtjevan proces, pri čemu je govornikova pažnja usmjerena prema planiranju i organizaciji govornih činova pod pritiskom vremena, a govornikov sustav ponekad ne uspijeva uskladiti procese proizvodnje na svim razinama. Također, govornikova pažnja je kod prepričavanja kronološkog redoslijeda radnje usmjerena prema procesima linearizacije makrorazine, to jest načinu na koji se višedimenzionalne sadržajne reprezentacije prevode u linearne jezične strukture. To je problem konceptualizacije koji Levelt (1989:138) objašnjava na sljedeći način »deciding what to say first, what to say next, and so on...«. 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 pojavljivanju različitih oblika disfluentnosti, među kojima su prekidi izričaja. Moguće je da su prekidi izričaja, te posljedično ponovna započinjanja, govornička navika, ali i strategija »kupovanja« dodatnog vremena koje je govorniku potrebno za organizaciju i izvedbu pod pritiskom vremena.

b) Leksičke pogreške

Uzoračke vrijednosti i veličine za učestalosti leksičkih pogrešaka na 100 riječi vidljive su iz tablice 14. Prema Shapiro-Wilkovom testu za učestalosti leksičkih pogrešaka na 100 riječi, tablica 15, ne postoji distribucija koja statistički značajno ne odstupa od normalne distribucije. *P*-vrijednost Friedmanovog testa iznosi 0.2274, tablica 16, te proizlazi da nisu dobivene statistički značajne razlike u učestalostima leksičkih pogrešaka na 100 riječi između pojedinih zadataka.

c) Morfološke pogreške

Uzoračke vrijednosti i veličine za učestalosti morfoloških pogrešaka na 100 riječi prikazane su u tablici 17. Provedba Shapiro-Wilkovog testa za učestalosti morfoloških pogrešaka na 100 riječi u svakom zadatku, tablica 18, dovodi do istog zaključka kao za prethodno analizirane kategorije pogrešaka, odnosno sve distribucije statistički značajno odstupaju od normalne distribucije. *P*-vrijednost Friedmanovog testa je manja od 0.0001, tablica 19, što znači da su dobivene statistički značajne razlike između poje-

dinih zadataka u učestalostima morfoloških pogrešaka. Kako su za SOBA1 i SOBA2 vrijednosti uzoraka jednake nuli sve do devetog decila (pod pojmom »sve vrijednosti« podrazumijevaju se one vrijednosti koje su predočene u tablici 17), Dunnovim testom se SOBA1 i SOBA2 uspoređuju s ostalim zadacima, tablica 20. Kako je vidljivo iz tablice 20, postoji statistički značajna razlika u učestalostima morfoloških pogrešaka u FILM-u u odnosu na SOBA1 i SOBA2. U FILM-u govornici trebaju zahtjevnu konceptualnu strukturu preslikati na površinsku formu. Budući da je više pažnje i vremena potrebno za planiranje poruke pod vremenskim pritiskom, manje vremena preostaje za nadgledavanje morfosintaktičke ispravnosti izričaja. Zbog povećanog napora u procesiranju i uslijed kognitivne složenosti zadatka, govornik odabire pogrešan morfološki oblik riječi, zato što u svom programu još nije odabrao riječ koja će biti izgovorena kasnije (Horga, 1997). Na drugoj strani, zadaci SOBA1 i SOBA2 (opisi prostorijski) kraće traju, a vrijeme pripreme i slikovni prikaz pomažu unaprijed odabrati pripadajuće morfološke nastavke odgovarajućih leksičkih jedinica.

E_L	<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	0.659	1.496	0.887	0.955	0
D_9	0.954	2.688	2.763	1.653	1.977
$x_{\max}$	2.033	5.263	6.098	3.077	4.545
d	2.033	5.263	6.098	3.077	4.545
d_Q	0.659	1.496	0.887	0.955	0
$\bar{x}$	0.336	0.718	0.644	0.483	0.437
σ	0.475	1.207	1.248	0.713	0.920
σ^2	0.226	1.457	1.558	0.508	0.846
$S_{\bar{x}}$	0.047	0.120	0.124	0.071	0.092
V	141.33 %	168.03 %	193.63 %	147.71 %	210.26 %
α_3	1.406	1.678	2.024	1.376	2.241
α_4	1.448	2.324	3.888	1.163	4.959

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 14: Uzoračke vrijednosti i veličine za učestalosti leksičkih pogrešaka na 100 riječi

Shapiro-Wilk	FILM	SOBA1	SOBA2	IZORE	STRIP
W	0.7448	0.6574	0.5895	0.7210	0.5456
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 15: Shapiro-Wilkov test normalnosti za učestalosti leksičkih pogrešaka na 100 riječi u J1

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	5.644	0.2274

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 16: Friedmanov test za učestalosti leksičkih pogrešaka na 100 riječi

<i>E_M</i>	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	0.565	0	0	0.735	0.887
D₉	0.800	0	0	1.124	2.488
x_{max}	1.460	5.263	2.500	2.381	4.110
d	1.460	5.263	2.500	2.381	4.110
d_Q	0.565	0	0	0.735	0.887
$\bar{x}$	0.300	0.217	0.108	0.333	0.592
σ	0.380	0.794	0.444	0.565	1.104
σ^2	0.144	0.630	0.197	0.319	1.219
S_{$\bar{x}$}	0.038	0.079	0.044	0.056	0.110
V	126.73 %	366.38 %	410.43 %	169.77 %	186.53 %
α_3	1.119	4.306	4.106	1.677	1.767
α_4	0.502	20.277	16.034	2.295	1.967

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 17: Uzoračke vrijednosti i veličine za učestalosti morfoloških pogrešaka na 100 riječi

Shapiro-Wilk	FILM	SOBA1	SOBA2	IZORE	STRIP
W	0.7875	0.3067	0.2576	0.6490	0.6021
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 18: *Shapiro-Wilkov test normalnosti za učestalosti morfoloških pogrešaka na 100 riječi*

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	49.139	< 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 19: *Friedmanov test za učestalosti morfoloških pogrešaka na 100 riječi*

Statistički značajna razlika može se primijetiti i između zadataka SOBA2 i STRIP. U STRIP-u ispitanici trebaju oblikovati priču na temelju pet prikazanih crteža i pažnja je usmjerena prema planiranju sadržaja, što rezultira statistički značajno većom učestalošću morfoloških pogrešaka u odnosu na zadatak SOBA2, a iz razloga navedenih kod usporedbe FILM-a sa SOBA1 i SOBA2.

Dunn	Razlika u sumi rangova	Statistički značajna razlika
FILM – SOBA1	86.5	Da
FILM – SOBA2	94	Da
SOBA1 – IZORE	–51	Ne
SOBA1 – STRIP	–52.5	Ne
SOBA2 – IZORE	–58.5	Ne
SOBA2 – STRIP	–60	Da

Tablica 20: *Dunnov test višestrukih usporedbi za učestalost morfoloških pogrešaka na 100 riječi*

d) Fonološke pogreške

Uzoračke vrijednosti i veličine za učestalosti fonoloških pogrešaka na 100 riječi vidljive su u tablici 21. Prema Shapiro-Wilkovom testu distribucije svih 5 populacija statistički značajno odstupaju od normalne distribucije, tablica 22. U tablici 23 prikazani su rezultati Friedmanovog testa za učestalosti fonoloških pogrešaka na 100 riječi. Proizlazi da nema statistički značajnih razlika između zadataka, jer je *p*-vrijednost 0.2192.

E_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
D₁	0	0	0	0	0
Q₁	0	0	0	0	0
Me	0	0	0	0	0
Q₃	0	0	0	0	0
D₉	0.361	0	0	0	0
$x_{\max}$	1.695	6.897	5.714	2.778	3.333
d	1.695	6.897	5.714	2.778	3.333
d_Q	0	0	0	0	0
$\bar{x}$	0.069	0.182	0.105	0.101	0.147
σ	0.221	0.915	0.631	0.400	0.548
σ^2	0.049	0.837	0.398	0.16	0.300
$S_{\bar{x}}$	0.022	0.091	0.063	0.040	0.055
V	321.51 %	502.42 %	600.11 %	393.84 %	373.37 %
α_3	4.833	5.751	7.645	4.659	4.196
α_4	29.930	35.364	64.547	23.977	18.106

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 21: Uzoračke vrijednosti i veličine za učestalosti fonoloških pogrešaka na 100 riječi

Shapiro-Wilk	<i>FILM</i>	<i>SOBA1</i>	<i>SOBA2</i>	<i>IZORE</i>	<i>STRIP</i>
W	0.3510	0.2051	0.1610	0.2811	0.2984
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 22: Shapiro-Wilkov test normalnosti za učestalosti fonoloških pogrešaka na 100 riječi u J1

Friedman	<i>n</i>	<i>df</i>	<i>F_r</i>	<i>p</i>
	101	4	5.743	0.2192

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 23: *Friedmanov test za učestalosti fonoloških pogrešaka na 100 riječi*

Vidljivo je da učestalost pojavljivanja leksičkih i fonoloških pogrešaka nije ovisna o vrsti zadatka, za razliku od gramatičkih pogrešaka (sintaktičkih i morfoloških) koje se statistički značajno češće pojavljuju kod opisivanja dinamičnih prostorno-vremenskih konstelacija. Kod takvih zadataka je pažnja naročito usmjerena prema planiranju i organizaciji govornih činova pod pritiskom vremena, a poteškoće na koje govornik nailazi rezultiraju statistički značajno većom učestalošću morfosintaktičkih pogrešaka.

8 Zaključak

Analiza govornog uzorka studenata tehničkih studija Fakulteta elektrotehnike, strojarstva i brodogradnje u trajanju od gotovo osam sati ukazala je na neke karakteristike govorne proizvodnje za govornike hrvatskog jezika. Distribucije pogrešaka, dobivene po razmatranim zadacima, ukazuju da je u svim zadacima sintaktička pogreška najzastupljenija kategorija. Slijede leksičke, zatim morfološke i na kraju fonološke pogreške koje se najrjeđe pojavljuju. Govornici nailaze na poteškoće prilikom oblikovanja izričaja, što se očituje učestalom pojavom prekida započetog izričaja. Prekidi i posljedično ponovna započinjanja javljaju se kao popratna pojava govornog planiranja i pokušaja da se uskladi govorni izraz s ostalim kognitivnim procesima.

Učestalost pojavljivanja leksičkih i fonoloških pogrešaka nije ovisna o vrsti zadatka, za razliku od gramatičkih (sintaktičkih i morfoloških), koje se statistički značajno češće pojavljuju kod opisivanja dinamičnih prostorno-vremenskih konstelacija u odnosu na zadatke kraćeg trajanja i drugačije prirode. Prepričavanje radnje je kognitivno složen i zahtjevan proces, pri čemu je govornikova pažnja usmjerena prema planiranju i organizaciji govornih činova pod pritiskom vremena, a govornikov sustav često ne uspijeva uskladiti procese proizvodnje na svim razinama u stvarnom vremenu. Moguće je da su prekidi te posljedično ponovna započinjanja govornička navika, ali i strategija „kupovanja» dodatnog vremena koje je govorniku potrebno za organizaciju govornih činova i izvedbu pod pritiskom vremena.

Za pretpostaviti je da su studenti tehničkih studija načelno manje orijentirani zadacima koji zahtijevaju govorničke vještine, a specifična priroda struke uglavnom ne nameće potrebu za njihovim razvojem. Potrebno je naglasiti da se i u smjernicama „Bolonjskog procesa» minimalizira potreba za usmenim ispitivanjem te se i na taj način u nastavi ne potiče svjesnost o nužnosti razvoja fluentnog govora. Zaključci proizišli iz ovog istraživanja bi mogli naći svoju praktičnu primjenu u nastavi *Komunikacijskih vještina* na tehničkim studijima. Bilo bi poželjno, koliko to vrijeme i nastavni plan dopuštaju, unaprijediti govorničke vještine kroz različite tipove zadataka i ukazivati

na potrebu nadgledavanja vlastitog govora. To se poglavito odnosi na praćenje pojavljivanja različitih vidova govornih disfluentnosti, u ovome slučaju učestalog prekidanja započetog izričaja.

Rezultati ovog rada nisu dobiveni na uzorku opće populacije. Buduća istraživanja bi mogla donijeti relevantne zaključke na temelju distribucija i učestalosti pogrešaka kod opće populacije. Također, bilo bi vrijedno istražiti kako sociolingvistički faktori i složenost samog jezika utječu na pogreške, te kako sugovornik ocjenjuje disfluentan govor.

LITERATURA

- A. A. AL-SUBAIHI, 2000: A Monte Carlo Study of the Friedman and Conover Tests in the Single-Factor Repeated Measures Design. *J. Statist. Comput. Simul.*, 65. 203–223.
- E. R. BLACKMER, J. L. MITTON, 1991: Theories of monitoring and the timing of repairs in spontaneous speech. *Cognition*, 39. 173–194.
- S. BREDART, 1991: Word interruption in self-repairing. *Journal of Psycholinguistic Research*, 20. 123–137.
- D. COIN, 2007: A goodness-of-fit test for normality based on polynomial regression. *Computational Statistics and Data Analysis*, 52. 2185–2198.
- A. CUTLER, 1983: Speakers' conceptions of the function of prosody. In: A. Cutler, i D. Ladd (Eds.), *Prosody: models and measurements*. Berlin/Heidelberg/New York/Tokyo. Springer Verlag.
- W. W. DANIEL, 1990: *Applied Nonparametric Statistics*. PWS-Kent Publishing Company.
- G. S. DELL 1986: A spreading activation theory of retrieval in sentence production. *Psychological Review*, 93. 283–321.
- G. S., DELL, P. A., REICH, 1981: Stages in sentence production: an analysis of speech error data. *J. Verbal Learning. Verbal Behaviour*, 20. 611–629.
- G. S., DELL, M. F., SCHWARTZ, N., MARTIN, E. M., SAFFRAN, D. A., GAGNON 1997: Lexical access in aphasic and non aphasic speakers. *Psychological Review*, 104. 801–838.
- J. DEMŠAR 2006: Statistical Comparisons of Classifiers over Multiple Data Sets. *Journal of Machine Learning Research*, 7. 1–30.
- K. DE SMEDT, G., KEMPEN, 1987: Incremental sentence production, self-correction and coordination. In: G. KEMPEN (Ed.), *Natural language generation: Recent advances in artificial intelligence, psychology and linguistics*, 365–376. Dordrecht, Netherlands: Kluwer.
- V. ERDELJAC, 2005: Govorne greške-pogled u strukturu mentalnoga leksikona, u: Granić, J. (ur.) *Semantika prirodnog jezika i metajezik semantike*, Zagreb-Split, Hrvatsko društvo za primijenjenu lingvistiku, 213–222.
- V. ERDELJAC, 2009: *Mentalni leksikon: modeli i činjenice*. Ibis grafika: Zagreb.
- A. FIELD, 2005: *Discovering Statistics using SPSS*. SAGE Publications: UK.
- J. E. FOX TREE, 1995: The effects of false starts and repetitions on the processing of subsequent words in spontaneous speech. *Journal of Memory and Language*, 34. 709–738.
- V. A. FROMKIN (Ed.), 1973: *Speech errors as linguistic evidence*. The Hague: Mouton Publishers.
- A. R. HENDERSON, 2006: Testing experimental data for univariate normality. *Clinica Chimica Acta*, 366. 112–129.
- D. HORGA, 1997: Samoispravljanje u govornoj proizvodnji. *Suvremena lingvistika*, 19. 91–104.
- D. HORGA, 2008: Prekid izričaja i ponavljanje u govornoj proizvodnji. *Philologica*, 11. 31–42.

- J. J. JAEGER, 2005: *Kids' slips. What young children's slips of the tongue reveal about language development*. Lawrence Erlbaum Associates Publishers, Mahwah, New Jersey and London.
- S. KESKIN, 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). 296–300.
- J. KORMOS, 2006: *Speech Production and Second Language Acquisition*, Lawrence Erlbaum Associates, New York London.
- W. J. M. LEVELT, 1983: Monitoring and self-repair in speech. *Cognition*, 33. 41–103.
- W. J. M. LEVELT, 1989: *Speaking: From intention to articulation*. Cambridge, MA: MIT Press.
- W. J. M. LEVELT, 1993: Language use in normal speakers and its disorders. In: G. Blanken, J. Dittmann, H. GRIMM, J. C. MARSHALL, C-W. WALLECH (Eds.), *Linguistic disorders and pathologies* (1–15). Berlin: deGruyter.
- W. J. M. LEVELT, 1995: The ability to speak: From intentions to spoken words. *European Review*, 3, 13–23.
- W. J. M. LEVELT, 1999: Language production: A blueprint of the speaker. In: C. Brown i P. Hagoort (Ed.), *Neurocognition of language*. 83–122. Oxford, England: Oxford University Press.
- D. MACKEY, 1987: *The organization of perception and action: A theory for language and other cognitive skills*. New York: Springer.
- J. P. MARQUES DE SA, 2007: *Applied Statistics Using SPSS, STATISTICA, MATLAB and R*. Springer Verlag: Berlin Heidelberg.
- D. C. MONTGOMERY, G. C. RUNGER, 2003: *Applied Statistics and Probability for Engineers*. John Wiley and Sons: USA.
- C. H. NAKATANI, J. HIRSCHBERG, 1994: A corpus-based study of repair cues in spontaneous speech. *The Journal of the Acoustical Society of America* 95, (3), 1603–1616 .
- S. NOOTEBOOM, 1980: Speaking and unspeaking: detection and correction of phonological and lexical errors in spontaneous speech. In: V. A. Fromkin (Ed.), *Errors in linguistic performance: slips of the tongue, ear, pen and hand*. Academic Press: New York. 87–96.
- S. G. NOOTEBOOM, 2005: Lexical bias revisited: Detecting, rejecting and repairing speech errors in inner speech. *Speech Communication*, 47. 43–58.
- M. A. PETT, 1997: *Nonparametric Statistics for Health Care Research*. Edition 2. Sage.
- Poulisse, N. (1999). *Slips of the tongue: Speech errors in first and second language production*. Amsterdam: Benjamins.
- A. POSTMA, 2000: Detection of errors during speech production: A review of speech monitoring models. *Cognition*, 77. 97–131.
- A. POSTMA, H. KOLK, 1993: The covert repair hypothesis: Prearticulatory repair processes in normal and stuttered disfluencies. *Journal of Speech and Hearing Research* 36. 472–487.
- A. ROELOFS, 1997: The WEAVER model of word-form encoding in speech production. *Cognition*, 64, 249–284.
- L. C. SHOAF, M. A. PITT, 2002: Does node stability underlie the verbal transformation effect? A test of node structure theory, *Perception and Psychophysics*, 64 (5). 795–803.
- E. E. SHRIBERG, 1994: Preliminaries to a Theory of Speech Disfluencies. Doctoral thesis. University of California, Berkley.
- J. P. STEMBERGER, 1985: An interactive activation model of language production. In: A. W. Ellis (Ed.), *Progress in the psychology of language* (143–186). Hillsdale NJ: Lawrence Erlbaum Associates.
- H. C. THODE, 2002: *Testing for normality*. Marcel Dekker: New York.

- M. A. VAN DE WIEL, 2004: Exact null distributions of quadratic distribution-free statistics for two-way classification. *Journal of Statistical Planning and Inference*, 120. 29–40.
- G. W. C. M. VAN HEST, 1996: *Self-repair in L1 and L2 production*. Tilburg University Press.
- C. VAN WIJK, G. KEMPEN, 1987: A dual system for producing self-repairs in spontaneous speech: evidence from experimentally elicited corrections. *Cognitive Psychology*, 19. 403–440.
- L. R. WHEELDON, W. J. M. LEVELT, 1995: Monitoring in the time course of phonological encoding. *Journal of Memory and Language*, 34. 311–334.
- J. ZHANG, W. YUEHUA, 2005: Likelihood-ratio tests for normality. *Computational Statistics and Data Analysis*, 49. 709–721.

POVZETEK

Govorne napake študentov tehničnih študijev

Skoraj osem ur trajajoča analiza vzorca govora študentov tehničnih študijev Fakultete za elektrotehniko, strojništvo in ladjedelništvo je pokazala nekatere karakteristike govorne proizvodnje pri govorcih hrvaškega jezika. Distribucija napak, pridobljena po ogledu nalog, kaže na to, da je v vseh nalogah sintaktična napaka najbolj zastopana kategorija. Sledijo leksikalne, nato morfološke in na koncu fonetične napake, ki se pojavljajo najredkeje. Govorci na težave naletijo pri oblikovanju izjave, kar razkriva pogosta pojavitev prekinitve začete izjave. Prekinitve in posledično ponovna začenjanja so spremljevalen pojav govornega načrtovanja in poskusa uskladitve govornega izraza z drugimi kognitivnimi procesi.

Pogostost pojavljanja leksikalnih in fonetičnih napak ni odvisna od vrste naloge. Slovnice (sintaktične in morfološke) pa se, nasprotno, pri opisu dinamičnih prostorsko-časovnih konstelacij pojavljajo statistično veliko pogostejše v primerjavi z nalogami krajšega trajanja in drugačne narave. Obnovitev dejanja je kognitivno zapleten in zahteven proces, pri katerem je govorčeva pozornost usmerjena na načrtovanje in organizacijo govornih dejanj pod težo časa, govorčevemu sistemu pa v dejanskem času pogosto ne uspe uskladiti procesov proizvodnje na vseh ravneh. Prekinitve ter posledično ponovna začenjanja so mogoče govorčeva navada, a tudi strategija »kupovanja« dodatnega časa, ki ga govorec potrebuje za organizacijo govornih dejanj in njihovo izvedbo pod težo časa.

Avtorja domnevata, da so študenti tehničnih študijev v načelu manj usmerjeni k nalogam, ki zahtevajo govorniške spretnosti, specifična narava stroke pa v glavnem ne vsiljuje potrebe po njihovem razvoju. Poudarjata, da se tudi v smernicah bolonjskega procesa minimalizira potreba po ustnem izpraševanju in se tako tudi v poučevanju ne spodbuja zavedanja o nujnosti razvoja tekočega govora. Sklepi, ki izhajajo iz te raziskave, bi svojo praktično uporabo lahko našli v poučevanju *Komunikacijskih spretnosti* na tehničnih študijih. Razvoj govorniške spretnosti bi bilo zaželeno, če to dopuščata čas in učni načrt, pospeševati z različnimi vrstami nalog in opozarjati na potrebo po nadzorovanju lastnega govora. To se zlasti nanaša na spremljanje pojavljanja različnih vrst netekočega govora, v tem primeru pogostega prekinjanja začete izjave.

Rezultati tega dela niso pridobljeni na vzorcu splošne populacije. Prihodnje raziskave bi lahko prinesle relevantne sklepe na podlagi distribucije in pogostnosti napak pri splošni populaciji. Prav tako bi bilo vredno raziskati, kako sociolingvistični dejavniki in zapletenost samega jezika vplivajo na napake ter kako sogovornik ocenjuje netekoči govor.