

Mjere rječničke raznolikosti kod pripovijedanja

Fratrić, Martina

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Education and Rehabilitation Sciences / Sveučilište u Zagrebu, Edukacijsko-rehabilitacijski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:158:160790>

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

Download date / Datum preuzimanja: **2024-06-13**



Repository / Repozitorij:

[Faculty of Education and Rehabilitation Sciences - Digital Repository](#)



Sveučilište u Zagrebu
Edukacijsko-rehabilitacijski fakultet

Diplomski rad
**Mjere rječničke raznolikosti kod
pripovijedanja**

Martina Fratrić

Zagreb, rujan 2019.

Sveučilište u Zagrebu
Edukacijsko-rehabilitacijski fakultet

Diplomski rad
**Mjere rječničke raznolikosti kod
pripovijedanja**

Martina Fratrić

doc. dr. sc. Gordana Hržica

Zagreb, rujan 2019.

Izjava o autorstvu rada

Potvrđujem da sam osobno napisala rad „*Mjere rječničke raznolikosti kod pripovijedanja*“ i da sam njegova autorica.

Svi dijelovi rada, nalazi ili ideje koje su u radu citirane ili se temelje na drugim izvorima jasno su označeni kao takvi te su adekvatno navedeni u popisu literature.

Ime i prezime: Martina Fratrić

Mjesto i datum: 2. rujna 2019.

Mjere rječničke raznolikosti kod pripovijedanja

Martina Fratrić

Doc.dr.sc. Gordana Hržica

Sveučilište u Zagrebu, Edukacijsko-rehabilitacijski fakultet, Odsjek za logopediju

Sažetak

Rječnik je ključan čimbenik jezičnog razvoja te usvajanja vještina čitanja i pisanja. Rječnički razvoj predstavlja osnovu za razvoj gramatike, sintakse i ostalih jezičnih sastavnica. Rječničko bogatstvo može se mjeriti pomoću mjera rječničke raznolikosti i mjere rječničke sofisticiranosti. Mjerama rječničke raznolikosti mjeri se raznovrsnost jezične proizvodnje, tj. koliko različitih riječi osoba koristi, dok se mjere rječničke sofisticiranosti temelje na promatranju uporabe riječi rijetke čestote. Cilj je ovog rada utvrditi mogu li mjere rječničke raznolikosti i sofisticiranosti razlikovati djecu različite kronološke dobi. U istraživanju je sudjelovalo 30 djece u dobi od 6;0 do 6;11 godina te 30 djece u dobi od 8;0 do 8;11 godina. Za dobivanje jezičnih uzoraka pripovijedanja upotrijebljen je Multilingual Assessment Instrument for Narratives (*MAIN*; Gagarina i sur., 2012; hrvatska inačica: Hržica i Kuvač Kraljević, 2012). Pripovjedni materijal transkribiran je u programu CLAN (MacWhinney, 2000) te su izračunate četiri mjere rječničke raznolikosti: broj različitih riječi (BRR), omjer različenica i pojavnica (ORP), pomični prosječni omjer različenica i pojavnica (MATTR), indeks rječničke raznolikosti D te mjera rječničke sofisticiranosti. Svi dobiveni podaci uneseni su i statistički obrađeni u SPSS programu. Rezultati su pokazali da se mlađa i starija skupina ispitanika statistički značajno razlikuju na mjerama BRR i D, na kojima mlađa djeca ostvaruju značajno niža postignuća, dok na mjerama ORP i MATTR nije dobivena statistički značajna razlika. Statistički značajna razlika nije dobivena ni na mjeri rječničke sofisticiranosti, iako mlađa skupina pokazuju tendenciju korištenja manjeg broja rijetkih riječi. Ovakvi rezultati mogu upućivati na manju rječničku raznolikost i sofisticiranost kod mlađe djece, ali je zbog neutvrđivanja značajne razlike na svim mjerama opravdanost za donošenje zaključaka o rječničkoj raznolikosti i sofisticiranosti ograničena. Posebno je teško donositi zaključke o rječničkoj sofisticiranosti jer metodologija izračuna ove mjere nije prilagođena hrvatskom jeziku, nego engleskom koji se znatno razlikuje od hrvatskog. Ograničenje istraživanja predstavlja i korištenje samo jedne vrste jezičnog uzorka te njihova ograničena duljina zbog koje nije bilo moguće pouzdano izračunati neke mjere. S obzirom na nedostatna istraživanja validacije ovih mjera za hrvatski jezik, svakako su potrebna daljnja istraživanja koja će uključivati ispitanike u većem rasponu kronološke dobi te različite vrste jezičnih uzoraka.

Ključne riječi (5): razvoj rječnika, rječnička raznolikost, mjere rječničke raznolikosti, rječnička sofisticiranost, računalna obrada uzoraka govornog jezika

Measures of lexical diversity in narration

Martina Fratrić

Doc.dr.sc. Gordana Hržica

University of Zagreb, Faculty of Education and Rehabilitation Sciences, Department of
Speech and Language Pathology

Summary

Vocabulary is a vital factor in language development and the acquisition of reading and writing skills. Vocabulary development is the foundation of grammar, syntax and other linguistic development. Lexical richness can be measured using lexical diversity measures and lexical sophistication measure. Lexical diversity measures the variety of language production, that is, how many different words a person uses, while lexical sophistication is based on observing the usage of the rare words. The aim of this study is to determine whether lexical diversity measures and lexical sophistication measure can distinguish children of different chronological ages. The study involved 30 children aged 6;0 to 6;11 and 30 children aged 8;0 to 8;11. Multilingual Assessment Instrument for Narratives (*MAIN*; Gagarina et al., 2012; Croatian version: Hržica and Kuvač Kraljević, 2012) was used for obtaining narrative samples. The narrative material was transcribed using the program CLAN (MacWhinney, 2000) and four measures of vocabulary diversity: number of different words (NDW), type-token ratio (TTR), measure D, moving average type-token ratio (MATTR) and lexical sophistication measure were calculated. All data were statistically analysed in the SPSS program. The results have shown that the younger and older group of respondents differed statistically significantly on the NDW and D, on which the younger children achieved significantly lower results, while no statistically significant difference was recorded on the TTR and MATTR measures. No statistically significant difference was recorded on the lexical sophistication measure, although the younger group tended to use fewer rare words.

Although these results can point to lower lexical diversity and sophistication among younger children, other measures of lexical diversity have not determined any differences. Therefore, the justification of drawing conclusions on lexical diversity and sophistication is limited. It is especially difficult to draw conclusions about lexical sophistication because the methodology for calculating this measure is not adapted to the Croatian language, but to English, which differs significantly from Croatian. The primary limitation of the research is the fact that only one type of language samples was used and its limited length, which made it impossible to reliably calculate some of the measures. Given the lack of research into the validation of these measures for the Croatian language, further research is needed that will include subjects across a larger chronological age range and different types of language patterns.

Key words (5): vocabulary development, lexical diversity, lexical diversity measures, lexical sophistication, natural language processing

Sadržaj:

1. UVOD	9
1.1. Razvoj rječnika	9
1.2. Rječnička raznolikost	10
1.3. Mjere rječničke raznolikosti	11
1.4. Rječnička sofisticiranost.....	15
1.5. Istraživanja o mjerama rječničke raznolikosti	16
2. CILJ ISTRAŽIVANJA	20
2.1. Istraživačka pitanja i problemi	20
2.2. Pretpostavke.....	20
3. METODE ISTRAŽIVANJA.....	21
3.1. Uzorak ispitanika	21
3.2. Mjerni instrumenti	22
3.3 Postupak ispitivanja.....	22
3.4. Obrada podataka	23
4. REZULTATI.....	26
5. RASPRAVA.....	29
6. OGRANIČENJA ISTRAŽIVANJA	35
7. ZAKLJUČAK	36
8. POPIS LITERATURE	38

Popis tablica:

Tablica 1. Osnovni podatci o skupinama ispitanika.....	22
Tablica 2. Prikaz i opis zavisnih varijabli.....	26
Tablica 3. Prikaz deskriptivnih rezultata asimetričnosti i spljoštenosti krivulje za zavisne varijable.....	26
Tablica 4. Osnovni statistički pokazatelji za mjere rječničke raznolikosti i mjeru rječničke sofisticiranosti.....	27
Tablica 5. Značajnost razlika između skupina ispitanika (t-test za nezavisne uzorke).....	28

Popis slika:

Slika 1. Matematički model rječničke raznolikosti.....12

Slika 2. Prikaz i usporedba prosječnih rezultata na mjerama rječničke raznolikosti i sofisticiranosti za obje skupine ispitanika.....28

1. UVOD

1.1. Razvoj rječnika

Usvajanje jezika jedan je vrlo složen zadatak postavljen pred većinu ljudi još u njihovom ranom djetinjstvu. Velik naglasak kod proučavanja usvajanja i učenja nekog jezika stavljen je upravo na riječi, odnosno rječnik (leksik). Riječi, kao temeljne jedinice nekog jezika, omogućuju pojedincu verbalnu komunikaciju sa okolinom. One ostvaruju arbitrarnu vezu između fonološkog (ili ortografskog) oblika i samog referenta kojeg predstavljaju. Može se reći da su riječi simboli, značenjske jedinice unutar jezika koje ljudima omogućuju međusobno dijeljenje informacija, tj. komunikaciju.

Procjenjuje se da prosječna odrasla osoba poznaje od 75 000 do 150 000 riječi, od čega 90% njih i aktivno upotrebljava (Libben i Jarema, 2002). Sve znanje o riječima koje osoba ima uskladišteno je u njezinom mentalnom leksikonu. Proučavanje razvoja rječnika kod djece zapravo je proučavanje njihovog mentalnog leksikona. Hoff (2001) daje sveobuhvatan pregled rječničkog razvoja djece urednog jezično-govornog razvoja, navodeći kako se razumijevanje riječi javlja prije njihove proizvodnje koja počinje s pojavom prve riječi. Prva riječ sa značenjem se kod djeteta u prosjeku javlja u dobi od oko 12 mjeseci. Jako brzo nakon pojave prve riječi, djeca kreću usvajati sve veći broj novih riječi koje su u početku usko vezane uz kontekst u kojem se usvajaju. U dobi od 18 mjeseci djeca poznaju oko 50 riječi. Nakon što dijete ima usvojeno 50 riječi, počinje razdoblje intenzivnog usvajanja riječi koje se još naziva i „rječnički brzac“ (Hoff, 2001). U tom razdoblju dijete usvaja 10 do 12 novih riječi svaki dan, a povezano je s kognitivnim promjenama koje ono doživljava. Porast rječnika nastavlja se i nakon ranog djetinjstva, čak i bržim tempom nego u predškolskom periodu (Anglin, 1993; prema Hoff, 2001). Tome pridonose sam porast u veličini djetetovog rječnika, porast znanja o tvorbi riječi te mogućnost učenja riječi iz konteksta. Važno je imati na umu da je od samih početaka učenja riječi taj proces individualan kod svakog djeteta, no brojnim istraživanjima razvoja dječjeg jezika dokazano je kako se razvoj rječnika kod djece ipak sastoji od nekih univerzalnih i slijednih razvojnih faza (Gentner, 1978, 1982; Nelson, 1973; Bloom, 1973; Benedict, 1979; Anglin, 1993; prema Hoff, 2001).

1.2. Rječnička raznolikost

Rječnički razvoj može se pratiti izračunavanjem mjera na različitim jezičnim uzrocima, a njima se može vršiti i sama procjena rječnika. Rječnički razvoj predstavlja osnovu za razvoj gramatike, sintakse i ostalih jezičnih sastavnica te ima jednu od ključnih uloga u jezičnom razvoju. Mjere kojima se služimo u praćenju razvoja rječnika nazivamo mjerama rječničke raznolikosti, a upravo se rječnička raznolikost kao pojam često poistovjećuje s rječničkim bogatstvom. Rječničko bogatstvo (engl. *lexical richness*) je nadređeni pojam koji obuhvaća konstrukte rječničke raznolikosti (engl. *lexical diversity*), rječničke sofisticiranosti (engl. *lexical sophistication*) i rječničke gustoće (engl. *lexical density*) (Read, 2000). Rječnička raznolikost odnosi se na opseg upotrijebljenih različitih riječi u jezičnom uzorku, gdje veći broj različitih riječi označava veću raznolikost (McCarthy i Jarvis, 2010). Rječnička sofisticiranost odnosi se na odgovarajuću upotrebu riječi koje se u jeziku rijetko pojavljuju, tj. upotrebu određenih tehničkih pojmova i neuobičajenih riječi koje omogućavaju osobi da izrazi značenja na precizan i sofisticiran način (Read, 2000), dok rječnička gustoća označava omjer punoznačnih riječi (imenica, glagola, pridjeva, priloga) i ukupnog broja riječi koje osoba upotrebljava u jezičnoj proizvodnji (Johansson, 2008).

Kad pretražujemo rječničku raznolikost kao pojam u literaturi, susrest ćemo se sa brojnim terminološkim nedoumicama. Tome doprinosi činjenica da se pojam upotrebljava kako bi označile jezične sposobnosti govornika nekog jezika (govorne i pisane), jednako kao i kvaliteta samih govornih i pisanih jezičnih produkata (Yu, 2009). Iako su govornici i njihovi jezični produkti naočigled povezani, rječnička raznolikost jezičnog produkta samo je statična manifestacija cjelokupne rječničke raznolikosti koja je u svojoj prirodi vrlo dinamična. Daljnji problemi s terminologijom javljaju se zbog česte naizmjenične uporabe brojnih sličnih termina umjesto ili zajedno s pojmom rječničke raznolikosti (Read, 2000). Raznolikost shvaćanja pojma rječničke raznolikosti vidljiva je i u knjizi „*Lexical Diversity and Language Development: Quantification and Assessment*“ u kojoj Malvern, Richards, Chipere i Dura'n (2004) navode kako su kroz povijest brojni istraživači iz područja primijenjene lingvistike pokušali osmisliti mjeru koja će označiti broj različitih riječi koje osoba upotrebljava u pisanju ili govoru, tj. mjeru koja govori o rječničkoj raznolikosti. Takve su mjere imale drugačije nazive i odražavale su razne koncepte, a neke od njih su:

- „rječnički raspon i ravnoteža“ (Crystal, 1982),
- „verbalna kreativnost“ (Fradis i sur., 1992),

- „fleksibilnost rječnika“ (McCarthy, 1954; Sherblom i Sherblom, 1987),
- „semantičke sposobnosti“, „semantička kompetencija“ ili „semantički čimbenici“ (Walker i sur., 1988; Watkins i sur., 1995; Ukrainetz i Blomquist, 2002);
- „cjelokupna jezična kvaliteta“ ili „jezična zrelost“ (Stewig, 1994);
- „ukupna veličina rječnika“ (Thomson i Thompson, 1915; Wagner i sur., 1987);
- „sklonost upotrebe rijetkih naspram čestih riječi“ (Spreen i Wachal, 1973);
- „čitljivost teksta“ (Tuldava, 1993);
- „lingvistička kompleksnost teksta“ (Simonton, 1989; Crain-Thoresen i sur., 2001) te brojne druge.


Iako su u ovom pregledu vidljive terminološke nedoumice oko rječničke raznolikosti, danas se ona najčešće označava kao „opseg upotrijebljenih različitih riječi u jezičnom uzorku“ (McCarthy i Jarvis, 2010). Navedena definicija rječničke raznolikosti upotrijebljena je i u ovom istraživanju u kojem će rječnička raznolikost i sofisticiranost biti istražene u dječjem jeziku. Koji god mjeru upotrebljavali u procjeni rječnika, svi istraživači slažu se u jednom - navodeći veću rječničku raznolikost kao prednost jer ona odražava bogatstvo rječnika nekog govornika te njegovu sposobnost da te riječi pravilno i smisljeno upotrebljava u svom jezičnom izričaju.

Mjere rječničke raznolikosti danas se upotrebljavaju u raznim područjima: u stilometriji, psihologiji, logopediji, forenzičnoj lingvistici, korpusnoj lingvistici te u primijenjenoj lingvistici vezanoj uz obrazovanje. S logopedskog gledišta najviše se primjenjuju u procjeni rječnika/jezika, u dijagnostici govorno-jezičnih poremećaja, kod proučavanja usvajanja drugog jezika - dvojezičnosti te u istraživanjima učinkovitosti brojnih terapijskih postupaka (Malvern i sur., 2004). Upravo je zbog mogućnosti ovako široke primjene mjera rječničke raznolikosti važno njihovo postojanje, isto kao i njihova teorijska utemeljenost.

1.3. Mjere rječničke raznolikosti

Prve kvantitativne mjere rječničkog razvoja; ukupan broj riječi (UBR; engl. *number of total words*, *NTW*), broj različitih riječi (BRR; engl. *number of different words*, *NDW*) i broj natuknica (engl. *number of lemmas*, *NLW*) bile su temelj za nastajanje prvog indeksa rječničke raznolikosti - omjera različenica i pojavnica (ORP - Kuvač i Palmović, 2007, engl. *type-token*

ratio, *TTR*). Takav omjer daje podatak o tome koliko je jezik složen ovisno o broju ponavljanih riječi, tj. on iskazuje udio različitih riječi koje se pojavljuju u jezičnom produktu. Iznos ORP-a može biti u rasponu od 0 do 1 (Slika 1.). Što je omjer različenica i pojavnica veći (bliži vrijednosti 1) to je veća rječnička raznolikost jer je u jezičnom produktu više novih riječi, a što je taj omjer manji (bliži vrijednosti 0) to je rječnička raznolikost manja jer je veći broj riječi koje se ponavljaju (Kuvač i Palmović, 2007). Bitno je napomenuti kako na ORP utječe duljina uzorka na koji se primjenjuje jer se s porastom duljine uzorka konstantno povećava broj pojavnica, dok se rast broja različenica postupno smanjuje. Drugim riječima, u duljim iskazima teže je izbjeći ponavljanja, a posebice ponavljanja visokofrekventnih funkcionalnih riječi. To svakako utječe na računanje ove mjere ukoliko se ona primjenjuje i uspoređuje među jezičnim uzorcima koji nisu iste duljine, stoga je za opravdano upotrebljavanje ove mjere potrebno uspoređivati uzorke jednake duljine. Važno je napomenuti i kako se pokazalo da je mjera ORP ovisna o prirodi određenog jezika (Kelić, Hržica i Kuvač Kraljević, 2012) te tako u hrvatskom, zbog bogate morfologije, ova mjera ima nešto više vrijednosti nego u ne tako morfološki bogatim jezicima. Dok u engleskom jeziku u svakodnevnoj konverzaciji vrijednost ORP-a rijetko prelazi vrijednost od 0.5 (Templin, 1957), u hrvatskom je ta vrijednost bliža 1. Razlog tome je da u obradi jezika računalo zamjećuje i uspoređuje samo nizove znakova pa će tako svaki puta različite oblike iste riječi označiti kao zasebnu različnicu te neće moći razlikovati homofone (riječi koje se isto pišu). Malvern i sur. (2004) napominju kako obje mjere - BRR i ORP imaju visoku osjetljivost na duljinu uzorka, stoga se mogu primjenjivati samo na jezičnim uzorcima iste ili vrlo slične duljine.



Slika 1. Matematički model rječničke raznolikosti (Malvern i sur., 2004)

Kako bi pokušali riješiti problem ovisnosti ORP-a o duljini uzorka, istraživači su pokušavali preoblikovati mjeru pomoću raznih matematičko-statističkih postupaka. Prvi takav pokušaj rezultirao je nastajanjem Maasovog indeksa (engl. *Maas index*, a^2 ; Maas, 1972; prema McCarthy i Jarvis, 2007) koji predstavlja mjeru utemeljenu na matematičkom principu linearizacije. McCarthy i Jarvis (2007), na temelju provedenog vlastitog istraživanja, zaključuju kako na ovu mjeru ne utječe duljina uzorka samo ukoliko se računa na tekstovima duljine 100–154, 154–333, 200–666 i 250–2,000 riječi. Nešto kasnije razvijane su i zasebne mjere koje se ne koriste običnim matematičkim transformacijama ORP-a, nego se temelje na nešto drugačijim načinima izračuna. Malvern i Richards (1997) kao mjeru rječničke raznolikosti koja ne ovisi o duljini uzorka predlažu indeks rječničke raznolikosti D (engl. *measure D*, D). Mjeru kasnije razrađuju Malvern i sur. (2004), a danas se računa pomoću *VOCD* (engl. *VOCabulary D*) programske podrške u programima za računalnu obradu jezika kao što je to CLAN (engl. *Computerized Language Analysis*). U računanju mjere D upotrebljava se matematički pristup prilagođavanja krivulje (engl. *curve-fitting approach*) (McKee, Malvern i Richards, 2000). Kako bi se izbjegao problem ovisnosti mjere o duljini uzorka, za stvaranje ORP krivulje upotrebljavaju se srednje vrijednosti dobivene na 100 slučajnih uzoraka koje čini 35-50 pojavnica iz teksta. Dobivena krivulja se zatim uspoređuje s nizom idealnih krivulja koje program stvara na temelju najviše i najniže moguće vrijednosti rječničke raznolikosti za taj tekst te se iz ove usporedbe dobiva vrijednost mjere D . Budući da se uzorci razlikuju sa svakim ponovljenim izračunom, postupak se ponavlja tri puta te se kao krajnji brojevi rezultat mjere uzima prosječna vrijednost. Zbog toga što se vrijednosti za krivulju izračunavaju na uzorcima od 35-50 pojavnica, potrebno je da uzorak sadrži najmanje 50 pojavnica (Malvern i sur., 2004). Iako navedeni matematički algoritam može izračunati vrijednost D -a i na manjem uzorku, pouzdanost takvih vrijednosti je pritom smanjena. McCarthy i Jarvis (2007; 2010) navode kako je, bez da na nju utječe duljina uzorka, ova mjera primjenjiva samo na onim uzorcima koji sadrže 100-400 pojavnica. Kao točniju i stabilniju mjeru navode hipergeometrijsku raznolikost indeksa D (engl. *hypergeometric diversity of D*, HD- D). Hipergeometrijska raspodjela u ovom slučaju omogućuje izvlačenje određenog broja pojavnica koje predstavljaju istu natuknicu iz uzorka određene duljine prema principu matematičke vjerojatnosti. Takva se raspodjela upotrebljava za računanje vjerojatnosti pojavljivanja svake različite neke natuknice u slučajnom uzorku sastavljenom od bilo koje 42 riječi iz uzorka. Vjerojatnosti za sve natuknice u uzorku se zatim zbrajaju te navedeni zbroj predstavlja mjeru rječnike raznolikosti, HD- D (McCarthy i Jarvis, 2010).

Pomični prosječni omjer različenica i pojavnica (engl. *moving-average type-token ratio*, MATTR; Covington, 2007) mjera je koja računa ORP na dijelovima uzorka, pomičući se kroz uzorak sve do njegovog kraja. Okvir izračunavanja ORP-a (broj riječi na kojima se izračunava) može se individualno podesiti, a krajnji rezultat koji predstavlja rječničku raznolikost zapravo je prosječna vrijednost dobivenih ORP vrijednosti. Covington i McFall (2010) opisuju ovu mjeru kao neovisnu o duljini uzorka te navode kako rezultat može ovisiti o širini odabranog okvira kojeg istraživači odabiru sami.

Za računanje rječničke raznolikosti u tekstu osmišljena je posebna mjera (engl. *measure of textual lexical diversity*, MTLTD) koja računa rječničku raznolikost u tekstu na način da ga odvaja u nizove sa istim ORP-om (zadano je da ORP iznosi 0.72) te zatim računa prosječnu duljinu nizova sa zadanim ORP-om (McCarthy, 2005). Novija istraživanja podupiru valjanost ove mjere, posebno za uzorke veće od 100 pojavnica (Koizumi i In'nami, 2012; Fergadiotis, Wright i Green, 2015).

Yu (2009) ističe kako, uz veličinu uzorka, rječnička raznolikost uvelike ovisi o poznavanju teme o kojoj se govori/piše, samoj mjeri rječničke raznolikosti koja se upotrebljava te vrsti jezičnog uzorka: govorni ili pisani. On je u svom istraživanju, u kojem je uspoređivao govorne i pisane uzorke istih govornika filipinskog, kineskog, perzijskog i ruskog jezika na mjeri D, dobio da je rječnička raznolikost veća kad je ispitanik upoznat s temom o kojoj govori ili piše. Analizom govornih i pisanih uzoraka istog govornika dobio je približno jednaku razinu rječničke raznolikosti za obje vrste uzorka. Nešto drugačije rezultate dobio je Biber (1988) koji je u svom istraživanju pronašao veću rječničku raznolikost pisanog jezika u odnosu na govorni. Kao mjeru rječničke raznolikosti Biber je upotrijebio je omjer različenica i pojavnica - ORP. Veća rječnička raznolikost pisanog jezika u odnosu na govorni jezik potvrđena je i u istraživanjima u hrvatskom jeziku (Olujić i Matić, 2017). Kao objašnjenje takvih rezultata, Olujić i Matić (2017) navode: „...kako bi pisani tekst nadomjestio sve one resurse za prijenos informacija koje govorni modalitet ima, za taj mu je prijenos potreban primarno velik broj različitih riječi, a čime se izravno povećava broj natuknica, kao i leksička raznolikost.“

1.4. Rječnička sofisticiranost

U istraživanjima se često uz mjere rječničke raznolikosti računa i mjera rječničke sofisticiranosti. Iako neki autori rječničku raznolikost i rječničku sofisticiranost smatraju razdvojenim konceptima (Read, 2000), neki rječničku sofisticiranost smatraju samo jednim aspektom rječničke raznolikosti. Laufer (2003) je tako, u svom istraživanju koje se bavi proučavanjem usvajanja drugog jezika, pod pojmom rječničke raznolikosti istraživala mjere rječničke raznolikosti, ali i mjeru rječničku sofisticiranosti. Takav koncept rječničke raznolikosti preuzet je i u ovom radu gdje će rječnička raznolikost biti istražena računanjem mjera rječničke raznolikosti i rječničke sofisticiranosti. Jedan od prvih autora koji govori o rječničkoj sofisticiranosti je Vermeer (2000). On predlaže da se umjesto na računanju distribucije ili povezanosti između različenica i pojavnica rječničko bogatstvo temelji na usporedbi koliko su riječi koje se upotrebljavaju „teške“, odnosno na tome kolika je njihova čestotnost pojavljivanja u korpusu. Takav koncept danas je u literaturi poznat pod nazivom *rječnička sofisticiranost* (Read, 2000, str. 203), a sam pojam odnosi se na upotrebu „osnovnog“ ili više „naprednog“ rječnika. Među istraživačima i danas postoje brojne rasprave oko toga koje to riječi pripadaju „naprednom“ rječniku. Arnaud (1984) i Linnarud (1986) sofisticiranima smatraju one riječi za čiju se upotrebu smatra da je iznad učenikove trenutne razine obrazovanja, dok Laufer (1990) pod „napredni rječnik“ svrstava sve one riječi koje se nalaze na posebno izrađenoj listi riječi (engl. *University Word List*, UWL; Nation, 1990). O nešto drugačijem načinu mjerenja rječničke sofisticiranosti govore Kyle i Crossley (2015) koji smatraju da su riječi koje se u govoru rjeđe upotrebljavaju sofisticiranije. Prema njima „osnovni“ rječnik predstavljaju riječi koje se imaju veliku pojavnost u nekom jeziku, dok se „napredni“ rječnik odnosi na riječi koje imaju malu pojavnost. Tidball i Treffers-Daller (2008) u svom su istraživanju određivali sofisticiranost riječi na temelju procjena učitelja o tome koliko je neka riječ teška za njihove učenike, a sličnu metodu za određivanje sofisticiranih riječi u turskom jeziku koriste i Demir-Vegter, Aarts, i Kurvers (2014). Za razliku od njih, Ravid (2006) je koristila nešto drugačiju metodu; razvrstavala je imenice prema njihovoj semantičkoj i formalnoj složenosti, od konkretnih do apstraktnih te je pritom apstraktne imenice označavala kao sofisticiranije. U literaturi pronalazimo različite načine računanja ove mjere, ali ono što ih uglavnom povezuje jest činjenica da je potrebno imati neke objektivne podatke o čestotnosti riječi; primjerice čestotni rječnik koji se dobiva na temelju analize jezičnih podataka iz korpusa. Naime, može postojati i neki drugačiji izvor čestotnosti: lista riječi nekog drugog korpusa, čestotni rječnik koji nije izrađen na korpusu na

kojem se radi, čestotna lista materijala na kojem se mjeri...Čestotnih rječnika govorenog jezika nema mnogo i postoje za ograničen broj jezika, primjerice za njemački (Jones i Tschirner, 2006) i engleski, za koji je moguće je naručiti ispisne čestotne liste podkorpora govorenog jezika najvećega korpusa američkog engleskog (engl. *Corpus of Contemporary American English*; Davies, 2008). Razlog tome je da je za izradu čestotnog rječnika nekog jezika potrebno ovladati i služiti se primarnim znanstvenometodološkim sredstvima analize korpusa što uključuje i mogućnost služenja specijaliziranim računalnim programima na relativno naprednoj razini. Posebice su rijetki samostalni čestotni rječnici dječjeg jezika, a kao glavni razlog navodi se zahtjevnost njihove izrade, posebice za morfološki bogate jezike (Hržica, Kuvač Kraljević i Šnajder, 2013). Sam koncept čestotnog rječnika danas je dosta zastario. Korpusi većinom imaju mogućnost lakog dohvata podataka o čestotnosti pomoću specijaliziranih preglednika (primjerice, *SketchEngine*; Kilgarriff i sur., 2014) te podatke o čestotnosti više nije potrebno objavljivati zasebno kao knjigu. Situacija je nešto drugačija kad se u obzir uzmu govoreni ili specijalizirani korpusi jer je u njima teško morfološki označiti riječi automatiziranim alatima, kao što je to kod korpusa pisanog jezika. Pisani i govorni jezik se u mnogočemu razlikuju pa će se tako razlikovati i njihovi čestotni rječnici, stoga je u mjerenju rječničke sofisticiranosti potrebno koristiti čestotne liste riječi dobivene na istoj vrsti uzorka na kojoj se primjenjuju (Lindqvist, Gudmundson i Bardel, 2013).

1.5. Istraživanja o mjerama rječničke raznolikosti i sofisticiranosti

Pri računanju mjera rječničke raznolikosti kod djece najviše se upotrebljavaju jezični uzorci spontanog govora, koje istraživači prikupljaju u interakciji s djetetom u igri ili tijekom snimanja interakcije roditelja i djeteta. Često se u istraživanjima starije djece i odraslih govornika upotrebljavaju i elicitirani uzorci pripovijedanja koji će biti upotrebljavani i u ovom radu. Pomoću raznih testova za procjenu rječnika (primjerice; *Peabody slikovni test rječnika*, PPVT) moguće je ispitati djetetov receptivni rječnik, dok nam mjere rječničke raznolikosti dobivene na govornim uzorcima pružaju uvid u djetetov ekspresivni rječnik i njegovu jezičnu produkciju od njegove najranije dobi. Mjere rječničke raznolikosti mogu se uspoređivati s rezultatima dobivenim na standardiziranim testovima s namjerom kako bi se utvrdila njihova valjanost te dobio uvid u cjelokupno jezično, odnosno rječničko znanje djeteta.

Pregledom literature na temu rječničke raznolikosti, uočava se da se u brojnim istraživanjima dječjeg jezika i rječničkog razvoja najčešće spominju i upotrebljavaju mjere: BRR, ORP, MATTR i D. Takva istraživanja, s raznovrsnim rezultatima, pružaju nam uvid u rječničku raznolikost djece te govore nešto više o primjeni i valjanosti navedenih mjera koje će biti predmet i ovog diplomskog rada.

Mnogi istraživači slažu se oko toga da ORP nije dobra mjera rječničke raznolikosti djece, iako je često upotrebljavana u istraživanjima (Hess, Haug i Landry, 1984; Malvern i sur., 2004; Koizumi i In'nami, 2012; Bernstein-Ratner i MacWhinney, 2016). Hess, Ritchie i Landry (1984), analizirajući jezičnu izvedbu djece u dobi od 6 do 8 godina, dobivaju da ORP ne korelira s djetetovom izvedbom na standardiziranim testovima procjene rječnika (PPVT, TOLD, Test pisanog jezika). Takve rezultate pokušali su objasniti tvrdnjom da ORP dobiven na uzorcima spontanog govora mjeri aspekt jezične izvedbe koji nije moguće mjeriti klasičnim standardiziranim testovima. Analizirajući transkripte spontanog govora nešto mlađe djece, u svom radu Bernstein-Ratner i MacWhinney (2016) ističu mjeru D kao bolji prediktor porasta djetetova rječnika i rječničke raznolikosti s povećanjem kronološke dobi, nego što je to ORP. Autori navode kako je D manje osjetljiv na duljinu uzorka te mu to daje prednost nad primjenom ORP-a na jezičnim uzorcima ograničene duljine, posebno kod djece niže kronološke dobi. Iako se vrijednost ORP-a uvijek kreće oko 0.5, male promjene njegovom u porastu s kronološkom dobi vidljive su već vrlo rano u jezičnom razvoju. U istraživanjima provedenim na uzorcima dječjeg spontanog govora dobiveno je kako prosječna vrijednost ORP-a u dobi 2;0-2;9 godina iznosi 0.447 (Hoerning i Retherford, 2006), dok u dobi od 3;0-3;9 godina ona iznosi 0.45 (Templin, 1957; Miller, 1991).

Klee (1992) je u svom istraživanju upotrebljavao transkripte spontanog govora djece starosti od 24 do 50 mjeseci te je, proučavajući jezične uzorke djece urednog jezično-govornog razvoja (UJR) i djece s razvojnim jezičnim poremećajem (RJP), došao do zaključka kako ORP ne može biti pouzdano rabljen u logopedskoj procjeni kao pokazatelj narušenog jezično-govornog razvoja. Za razliku od ORP-a, mjera BRR može odijeliti ove dvije skupine djece te ima visoku korelaciju s dobi djeteta, što je i u skladu s prethodnim navodima Templin (1957). O porastu ukupnog broja riječi s kronološkom dobi govori i Miller (1991) koji navodi kako BRR pozitivno korelira s djetetovom dobi kad se u obzir uzmu uzorci spontanog govora, jednako kao i kad se upotrebljavaju uzorci pripovijedanja. S prethodnim rezultatima slažu se i Watkins, Kelly, Harbers i Hollis (1995) koje, uspoređujući djecu UJR-a i djecu s RJP-om na mjerama BRR i ORP, zaključuju kako je BRR puno osjetljivija mjera u razlikovanju

navedenih skupina djece. Autorice navode kako djeca s RJP-om na uzorcima spontanog govora duljine 50 i 100 iskaza proizvode statistički značajno manji broj različitih riječi (manji BRR) nego njihovi vršnjaci UJR-a.

Kad se navedene skupine djece uspoređuju na mjeri D, zanimljive rezultate prikazuju Owen i Leonard (2002). One navode kako se djeca s RJP-om ne razlikuju od svojih vršnjaka UJR-a na mjeri D kad se u obzir uzmu uzorci spontanog govora duljine 250 iskaza. Autorice napominju da, kad se u obzir uzmu skupine djece sa manjom prosječnom duljinom iskaza, djeca s RJP-om ostvaruju više rezultate na mjeri D od mlađe djece UJR-a izjednačene po prosječnoj duljini iskaza što može bit znak određene osjetljivosti ove mjere o duljini uzorka. U radu ističu i kako starija djeca iz obje skupine (UJR-a i RJP-a) ostvaruju više rezultate na mjeri D što povezuju s većom prosječnom duljinom iskaza kod djece veće kronološke dobi. Jarvis (2002) u svom radu uspoređuje rječničku raznolikost između finske djece koja uče engleski i djece izvornih govornika engleskog jezika rabeći mjere dobivene na pisanim uzorcima. Autor navodi kako djeca izvorni govornici engleskog jezika ostvaruju više rezultate na mjeri D od onih koji engleski uče kao strani jezik te da mlađa skupina učenika izvornih govornika ostvaruje niže vrijednosti na mjeri D od starije skupine učenika izvornih govornika. Iz navedenih rezultata istraživanja vidljivo je kako mjera D može odijeliti djecu različite kronološke dobi kad se radi o govornim, ali i o pisanim jezičnim uzorcima.

O primjeni MATTR-a u istraživanjima rječničke raznolikosti dječjeg jezika u literaturi je vrlo teško pronaći podatke. Ova mjera najviše se upotrebljava kod proučavanja rječničke raznolikosti odraslih osoba s afazijom. Fergadiotis, Wright i West (2013) u svom su istraživanju procjenjivali valjanost četiriju mjera rječničke raznolikosti: MTLA-a, MATTR-a, ORP-a i mjere D kod osoba s afazijom. Na početku je provedena potvrdna faktorska analiza kako bi odredili mjere li svi računalni alati koji se upotrebljavaju za računanje mjera isti konstrukt i koliko dobro to čine te su nakon toga, analizom 101 jezičnog uzorka pripovijedanja, zaključili kako su sve četiri mjere pouzdane i kako su sve vrlo dobri pokazatelji rječničke raznolikosti. Posebno se dobrim pokazao MATTR jer smatraju da na njega najmanje utječe duljina uzorka te je, za razliku od mjera ORP i D, imao malu rezidualnu varijancu. Autori ipak napominju da, kako bi se uz pomoć ove mjere vrlo precizno odredila rječnička raznolikost neke osobe, potreban je velik jezični uzorak (oko 10 000 riječi) što je gotovo nemoguće dobiti u istraživanjima dječjeg jezičnog razvoja.

Istraživanja rječničke sofisticiranosti još nisu provedena u hrvatskom jeziku, dok su u engleskom jeziku najviše usmjerena na pisani jezik (Breeze, 2008; Crossley i McNamara, 2009; Laufer i Nation, 1995; Mazgutova i Kormos, 2015; prema Palfreyman i Karaki, 2017). Jedna od najstarijih i najviše upotrebljivanih mjera za računanje rječničke sofisticiranosti u engleskom jeziku je Profil čestotnosti rječnika (engl. *Lexical frequency profile*, LPF) (Laufer i Nation, 1995). Profil se izrađuje na način da se analizom pisanog uzorka odijele i prebroje riječi, tj. da se prebroji koliko se riječi nalazi unutar svakog od četiri razreda; prvih 1000 najčešćih riječi, drugih 1000 najčešćih riječi, riječi s popisa akademskih riječi (engl. *Academic Word List*, AWL; Coxhead, 2000) te riječi koje se ne nalaze ni na jednom od popisa. Lindqvist i sur. (2013) su istraživali rječničku sofisticiranost kod švedskih učenika koji uče francuski i talijanski kao strani jezik koristeći naprednu metodu jer su lematizaciju pojavnica vršili uz pomoć računalnih alata TreeTagger (Schmid, 1994, 1995) i WordSmith (Scott, 2004). Autori su sve natuknice iz korpusa podijelili u razrede prema čestotnosti njihove uporabe kako bi kasnije mogli izmjeriti rječničku sofisticiranost izrađujući Rječnički profil govorne produkcije (engl. *Lexical Oral Production Profile*, LOPP) za svakog učenika. Neka istraživanja rječničke sofisticiranosti pokazuju kako mjere rječničke raznolikosti i sofisticiranosti imaju vrlo slabu povezanost (Šišková, 2012) te kako je rječnička sofisticiranost veća ukoliko se učenicima da više vremena da isplaniraju ono što će reći, dok to ne utječe na povećanje rječničke raznolikosti (Skekan i Foster, 2012).

Jedan od razloga nastanka ovog rada je činjenica da se u istraživanjima rječničke raznolikosti u hrvatskom jeziku najviše koriste tradicionalne mjere kao što su BRR i ORP (Kelić i sur., 2012; Miličić, Kuvač Kraljević i Lenček, 2017; Olujić i Matić, 2017; Topal, 2018), dok su istraživanja koja upotrebljavaju druge mjere rijetka. Ona se pojavljuju tek nedavno, ali u jeziku odraslih osoba. Radovi o rječničkoj raznolikosti u dječjem jeziku općenito se drže tradicionalnijih mjera, stoga je bitno istražiti i druge mjere kako bi se dobio bolji uvid u rječnički razvoj i rječničko znanje djece.

2. CILJ ISTRAŽIVANJA

Pregledom brojne literature uočeno je da postoji više mjera rječničke raznolikosti koje se upotrebljavaju u istraživanjima vezanim uz proučavanje rječničkog razvoja djece. Cilj je ovog diplomskog rada istražiti može li se rječnički razvoj djece odraziti u mjerama rječničke raznolikosti te će se, primjenjujući četiri mjere rječničke raznolikosti i mjeru rječničke sofisticiranosti na jezične uzorke pripovijedanja, utvrditi postoji li razlika na navedenim mjerama između djece različite kronološke dobi.

2.1. Istraživačka pitanja i problemi

Istraživači se već dugi niz godina pokušavaju dogovoriti o tome koja bi bila najbolja i jedinstvena mjera rječničke raznolikosti. Valjanost mjera rječničke raznolikosti predmet je brojnih istraživanja, a najviše je onih s engleskog govornog područja. U ovom radu želi se utvrditi valjanost četiriju mjera rječničke raznolikosti (BRR-a, ORP-a, D-a, MATTR-a) te mjere rječničke sofisticiranosti, rabeći i uspoređujući jezične uzorke pripovijedanja djece izvornih govornika hrvatskog jezika koji se razlikuju po kronološkoj dobi. Od ranije je iz literature poznato da na mjere BRR i ORP utječe duljina uzorka, dok na mjere D i MATTR ne utječe (Malvern i Richards, 1997; Covington i McFall, 2010) te se zbog toga nameće pitanje mogu li mjere na koje utječe duljina uzorka bolje razlikovati djecu različite kronološke dobi od onih na koje duljina uzorka ne utječe. Jednako tako, javlja se i pitanje može li mjera rječničke sofisticiranosti odijeliti djecu različite kronološke dobi te na taj način odraziti porast u rječničkom znanju djeteta.

2.2. Pretpostavke

U prethodno navedenim istraživanjima mjera rječničkog razvoja nisu uvijek rabljeni jezični uzorci pripovijedanja koji će se upotrebljavati u ovom radu. Unatoč razlici u vrsti govornog uzorka na kojem će se mjere računati, pretpostavlja se da će rezultati ovog rada biti vrlo slični onima dobivenim na jezičnim uzorcima spontanog govora. Stoga, na temelju prijašnjih

istraživanja te u skladu s postavljenim ciljem i problemom istraživanja postavljene su sljedeće hipoteze:

H₁: Mjere rječničke raznolikosti koje ovise o duljini jezičnog uzorka (BRR i ORP) razlikovat će djecu različite kronološke dobi.

H₂: Mjere rječničke raznolikosti koje ne ovise o duljini jezičnog uzorka (D i MATTR) razlikovat će djecu različite kronološke dobi.

H₃: Mjera rječničke sofisticiranosti razlikovat će djecu različite kronološke dobi.

3. METODE ISTRAŽIVANJA

3.1. Uzorak ispitanika

U istraživanju su sudjelovale dvije skupine ispitanika koje su sastavljene od predškolske djece u dobi od 6;0 do 6;11 godina te školske djece u dobi od 8;0 do 8;11 godina. Kriterij za odabir sudionika obje skupine osim kronološke dobi bio je i da su sva djeca urednog jezičnog govornog razvoja. Svaka skupina sastavljena je od 30 djece. Mlađa skupina ispitanika (prosječna dob 6;06 godina) sastavljena je od 14 dječaka i 16 djevojčica koji su pohađali predškolske ustanove na području grada Zagreba i u njima su u trenutku ispitivanja boravili barem šest mjeseci. Stariju skupinu ispitanika (prosječna dob 8;05 godina) čini 16 dječaka i 14 djevojčica koji su pohađali drugi razred osnovne škole na području grada Zagreba. Roditelj svakog djeteta dao je suglasnost za sudjelovanje u istraživanju. Uzorci pripovijedanja za mlađu skupinu prikupljeni su u sklopu projekata: „Language Dominance of Bilingual Speakers Perceived as Balanced (LADOBI, Piscopia Marie Curie Action (COFUND), Okvirni program 7 (FP7))“, dok su uzorci pripovijedanja za stariju skupinu ispitanika prikupljeni u sklopu projekta „Višerazinski pristup govornom diskursu u jezičnom razvoju (Hrvatska zaklada za znanost, UIP-2017-05-6603)“ .

Tablica 1. Osnovni podatci o skupinama ispitanika

skupina	mlađa djeca	starija djeca
Broj sudionika	30	30
Spol	Ž =16, M = 14	Ž = 14, M = 16
Kronološka dob (raspon)	6;0 - 6;11	8;0 - 8;11
Kronološka dob (prosjeak)	6;06	8;05
Kronološka dob (standardna devijacija)	0.032	0.037

3.2. Mjerni instrumenti

U oba projekta uzorci pripovijedanja prikupljeni su pomoću instrumenta *Multilingual Assessment Instrument for Narratives (MAIN; Gagarina i sur., 2012, MAIN - hrvatska inačica: Višejezični instrument za ispitivanje pripovijedanja; Hržica i Kuvač Kraljević, 2012)*. MAIN je višejezični materijal za ispitivanje pripovijedanja, odnosno pripovjednih vještina djece koja usvajaju jedan ili više jezika. Ovaj instrument sastoji se od četiri usporedne priče – dvije za pripovijedanje (Koze i Ptice) i dvije za prepričavanje (Mačka i Pas). U ovom istraživanju su za računanje mjera rječničke raznolikosti i sofisticiranosti rabljene samo priče za pripovijedanje (Koze i Ptice). Unutar svake skupine pola ispitanika je pripovijedalo priču Koze, a pola priču Ptice. Pripovijedanje se u MAIN-u potiče uporabom slikovnog predloška koji se sastoji od niza od šest pažljivo kontroliranih slika. Obje priče su kontrolirane s obzirom na kognitivnu i lingvističku složenost, kulturološku prikladnost te usporednost u makro- i mikrostrukturi. Iako MAIN još nije standardiziran za hrvatski jezik, može se upotrebljavati u procjeni i istraživanjima zbog visoke ujednačenosti, kontroliranosti i standardizirane procedure (Gagarina i sur., 2012).

3.3 Postupak ispitivanja

Obje skupine ispitivane su tijekom boravka u predškolskoj, odnosno školskoj ustanovi. Ispitivanje se provodilo na način da su svoj djeci osigurani jednaki uvjeti; djeca su za vrijeme ispitivanja izdvojena iz skupine/razrednog odjeljenja u tihu prostoriju s najmanjom prisutnošću okolinske buke. Ispitanicima su na prijenosnom računalu bila prikazana četiri

polja označena brojevima, a svaki broj označavao je jednu priču. Zadatak svakog djeteta bio je odabrati jednu od ponuđenih priča, na način da ispitivač ne vidi koju priču je dijete odabralo s ciljem osiguravanja uvjeta nezdržene pažnje (engl. *non-shared attention*). Ispitivač je znao o kojoj se priči radi jer su sve priče bile iste, a svrha takvog ispitivanja je da dijete misli da ispitivač ne zna sadržaj priče. Na ovaj način kontrolira se utjecaj zajedničkog znanja na informacije koje će dijete dati ispitivaču (engl. *the effect of shared knowledge*). Nakon odabira priče, na prijenosnom računalu ispitanicima je prikazan niz slika koje su oni najprije pregledali, a zatim je proveden zadatak pripovijedanja na temelju onoga što su vidjeli. Ispitivačevi poticaji i svaki oblik pomaganja djetetu tijekom provedbe zadatka pripovijedanja svedeni su na minimum (dopušteni oblici ispitivačevih poticaja mogu se pronaći u MAIN priručniku Gagarine i sur. iz 2012.). Njihovo je pripovijedanje, uz suglasnost roditelja, snimano radi kasnije transkripcije i obrade podataka.

3.4. Obrada podataka

Svi snimljeni uzorci pripovijedanja transkribirani su i kodirani prema sustavu CHAT-a (engl. *Codes for the Human Analyses of Transcripts*; MacWhinney, 2000) koji služi za oblikovanje prijepisa govora te se sastoji od kodova kojima se transkribira i kodira zapis dječjega jezika. Prilikom transkripcije snimljenih uzoraka granice između rečenica određivane su na temelju sintaktičkih pravila kako bi se dobile cjeline koje se nazivaju komunikacijske jedinice (engl. *communication unit/C-unit*; Loban, 1966). Jedna komunikacijska jedinica može biti jednostavna rečenica (rečenica koja sadrži samo jedan predikat), zavisnosložena rečenica (subjektna, predikatna, objektna rečenica itd.) ili surečenica nezavisnosložene rečenice (rečeničnog niza, sastavne, rastavne rečenice itd.). U transkripciji su eliminirani svaki oblici komunikacije osim djetetovog pripovijedanja (npr. tehničke upute ispitivača), a jedina iznimka bili su iskazi i poticaji ispitivača koji odstupaju od pravila u priručniku. Nakon transkripcije su u računalnom programu CLAN-u (engl. *Computerized Language Analysis*; MacWhinney, 2000), koji omogućava fonološku, morfološku i sintaktičku analizu zapisa, izračunate mjere rječničke raznolikosti i sofisticiranosti za svakog ispitanika. CHAT i CLAN dijelovi su svjetske baze dječjega jezika (engl. *Child Language Data Exchange System*, CHILDES; MacWhinney, 2000).

U programu CLAN određene su četiri mjere rječničke raznolikosti: broj različitih riječi (BRR), omjer različenica i pojavnica (ORP), pomični prosječni omjer različenica i pojavnica (MATTR) te indeks rječničke raznolikosti D. Mjera ORP temelji se na mjeri BRR pa je tako obje mjere moguće izračunati pomoću naredbe *FREQ*. Naredba *FREQ* će unutar svakog transkripta, tj. za svakog ispitanika izračunati ukupan broj različenica i pojavnica te izračunati njihov omjer čime se dobiva vrijednost mjere ORP. Različnica je jedinstveni niz znakova koji je različit od svakog drugog niza znakova, dok je pojavnica svaka riječ koju program CLAN prepoznaje, odnosno niz znakova između bjelina koji uključuje i ponavljanja (Jelaska, 2005). Broj različitih riječi zapravo je broj različenica (engl. *types*) te su primjenom ove naredbe dobiveni podatci za obje navedene mjere rječničke raznolikosti. Iako je ORP najraširenija mjera rječničke raznolikosti, zbog njezinih nedostataka (najviše u pogledu ovisnosti o duljini uzorka) i dodatne sigurnosti izračunate su još dvije mjere rječničke raznolikosti; MATTR i D. Mjera MATTR je u CLAN-u također izračunata pomoću naredbe *FREQ*, samo što je u ovom slučaju bilo potrebno dodati kod $+bN$ u kojem N predstavlja broj riječi koje će biti rabljene u pomičnom okviru koji računa ORP vrijednosti u uzorku. Imajući na umu da su transkripti koje se u ovom radu upotrebljavalo za računanje mjera relativno kratki, u pomični okvir uzeto je 10 riječi te je dobivena vrijednost mjere MATTR koja zapravo predstavlja prosječnu vrijednost svih omjera različenica i pojavnica u zadanom uzorku. Mjera D je u CLAN-u izračunata pomoću VOCD programa upotrebom istoimene naredbe. Prednost je ove mjere da se ona ne izračunava na temelju stvarnih riječi kao ORP, nego se računa na temelju vjerojatnosti pojave novih riječi u duljim uzorcima. Zbog same veličine transkripta, prilikom računanja mjere D bilo je potrebno dodati kod $+br$ kako bi program izračunao točne vrijednosti i za one uzorke koji imaju manji broj pojavnica od onog broja koji je predviđen samim programom. Također, prilikom upisivanja naredba *FREQ* i *VOCD* upotrijebljen je i kod $+t*CHI$ kako bi u računanje mjera rječničke raznolikosti bili uključeni samo iskazi ispitanika - djece, a ne i ispitivača koji su, u nekim slučajevima, dodatnim pitanjima i komentarima poticali djecu na pripovijedanje.

Postoje razne metode pomoću kojih istraživači računaju mjeru rječničke sofisticiranosti. U hrvatskom jeziku nema istraživanja koja bi govorila o metodama izračuna mjere rječničke sofisticiranosti. S obzirom na činjenicu da je hrvatski morfološki bogat jezik, što ga razlikuje od engleskog za kojeg postoji najviše istraživanja ove mjere, nije bilo moguće direktno primijeniti metode niti programe iz njihovih istraživanja i na ove uzorke. Također, podaci o čestotnosti riječi u dječjem jeziku u trenutku pisanja ovog rada nisu javno objavljeni, iako je

Hrvatski čestotni rječnik dječjega jezika (*DjeČeR*; Hržica, Kuvač Kraljević i Šnajder, 2013) bio u izradi. Za potrebe ovog istraživanja izrađena je lista najrjeđih riječi na temelju prikupljenih uzoraka pripovijedanja. Kako bismo dobili listu najrjeđih riječi na temelju koje će se računati rječnička sofisticiranost, u programu CLAN prvo je bilo potrebno pomoću naredbe *FREQ +o +u +t*CHI* napraviti abecedni popis različenica svih ispitanika zajedno. Navedeni kod omogućuje brojanje čestotnosti (*FREQ*) tretirajući sve transkripte kao jednu bazu (*+u*). Kao što je već ranije spomenuto, bilo je potrebno i ograničiti brojanje različenica samo na iskaze ispitanika (*+t*CHI*). Iz navedenog popisa su zatim bile odabrane sve one različenice koje su se u transkriptima javile manje od 10 puta te je njihovom lematizacijom dobivena lista najrjeđih natuknica. U sljedećem koraku je u svakom transkriptu izbrojano koliko se ukupno natuknica u njemu pojavljuje te koliko njih se nalazi na listi najrjeđih. Kao konačna brojana vrijednost mjere rječničke sofisticiranosti za svakog ispitanika uzet je brojčani omjer najrjeđih natuknica i ukupnog broja natuknica koje se javljaju u djetetovom pripovijedanju. U procjeni rječničke sofisticiranosti korištene su natuknice jer u svom radu Lindqvist i sur. (2013) napominju kako brojanje natuknica omogućava da se u obzir uzmu svi oblici neke riječi koje nisu upotrijebljeni u uzorku, a za koje se pretpostavlja da ih govornik zna. Autori su za svakog učenika izrađivali već spomenuti profil govorne produkcije, dok je u ovom radu zbog nedovoljnog znanja služenja specijaliziranim računalnim programima izračunat samo postotak rijetkih natuknica koje ispitanik upotrebljava u svojoj govornoj produkciji, odnosno pripovijedanju.

Vrijednosti svih navedenih mjera unesene su i statistički obrađene pomoću programa IBM Statistical Package for the Social Sciences (SPSS), inačica 20. Prije same odluke o odabiru parametrijske ili neparametrijske statistike za obradu podataka, provjereni su statistički preduvjeti o normalnosti raspodjele za svaku varijablu. Kriterij za prihvaćanje normalnosti raspodjele bio je da su vrijednosti spljoštenosti krivulje (engl. *kurtosis*) i asimetričnosti krivulje (engl. *skewness*) u rasponu od -1,5 do 1,5. Utvrđeno je kako sve varijable imaju normalnu raspodjelu te je njihova analiza provedena uz pomoć t-testa za nezavisne uzorka iz područja parametrijske statistike.

Tablica 2. Prikaz i opis zavisnih varijabli

Kratica	Opis varijable
BRR	Broj različitih riječi
ORP	Omjer različenica i pojavnica
D	Indeks rječničke raznolikosti D
MATTR	Pomični prosječni omjer različenica i pojavnica
RJ_SOF	Mjera rječničke sofisticiranosti

Tablica 3. Prikaz deskriptivnih rezultata asimetričnosti i spljoštenosti krivulje za zavisne varijable

mjere	<i>asimetričnost (skewness)</i>	<i>spljoštenost (kurtosis)</i>
BRR	0,861	1,136
ORP	0,197	-0,336
MATTR	-0,620	1,293
D	0,436	-0,479
RJ_SOF	-0,264	-0,027

4. REZULTATI

Za sve zavisne varijable izračunati su podaci deskriptivne statistike. Deskriptivna analiza za rezultate na varijablama rječničke raznolikosti i varijabli rječničke sofisticiranosti prikazana je u Tablici 4.

Na svim mjerama rječničke raznolikosti skupina osmogodišnjaka pokazuje više srednje vrijednosti (aritmetička sredina, M) od skupine šestogodišnjaka. Raspršenja rezultata oko srednje vrijednosti (standardna devijacija, SD) na mjerama BRR i ORP su veća kod osmogodišnjaka u odnosu na šestogodišnjake, dok su na mjerama MATTR i D u skupini osmogodišnjaka ona manja. Na mjeri rječničke sofisticiranosti više srednje vrijednosti postiže

skupina osmogodišnjaka, dok veće raspršenje rezultata unutar skupine postiže skupina šestogodišnjaka.

Tablica 4. Osnovni statistički pokazatelji za mjere rječničke raznolikosti i mjeru rječničke sofisticiranosti


varijabla	skupina	min.	max.	M	SD
BRR	šestogodišnjaci	27	79	42,23	15,11
	osmogodišnjaci	21	103	51,87	15,37
ORP	šestogodišnjaci	0,444	0,762	0,590	0,076
	osmogodišnjaci	0,419	0,766	0,594	0,081
MATTR	šestogodišnjaci	0,798	0,943	0,899	0,031
	osmogodišnjaci	0,853	0,966	0,908	0,030
D	šestogodišnjaci	7,48	27,22	13,34	8,85
	osmogodišnjaci	8,02	30,55	17,83	5,26
RJ_SOF	šestogodišnjaci	0,63	0,86	0,739	0,058
	osmogodišnjaci	0,64	0,81	0,755	0,039

Za daljnju statističku obradu proveden je t-test za sve varijable (sve navedene varijable prate normalnu raspodjelu), s ciljem utvrđivanja razlika između skupine šestogodišnjaka i osmogodišnjaka. Vrijednosti testova za pojedine varijable prikazane su u Tablici 5. Primjenom t-testa utvrđeno je da se dvije skupine ispitanika statistički značajno razlikuju na varijabli BRR ($t=-2,45$, $df=58$, $p<0,05$). Starija skupina ispitanika upotrebljava statistički značajno veći broj različitih riječi ($M=51,87$, $SD=15,37$) od mlađe skupine ispitanika ($M=42,25$, $SD=15,11$). Statistički značajna razlika dobivena i je na varijabli D ($t=-3,123$, $df=58$, $p<0,05$). Starija skupina djece, osmogodišnjaci, postižu statistički značajno više rezultate na mjeri D ($M=17,83$, $SD=5,26$) od mlađe skupine ispitanika, šestogodišnjaka ($M=13,34$, $SD=8,85$). Razlika između mlađe i starije skupine ispitanika na varijabli ORP nije statistički značajna ($t=-0,19$, $df=58$, $p>0,05$), kao ni razlika na varijabli MATTR ($t=-1,224$, $df=58$, $p>0,05$). Na varijabli rječničke sofisticiranosti nije dobivena statistički značajna razlika između šestogodišnjaka i osmogodišnjaka ($t=-1,283$, $df=58$, $p>0,05$).

Tablica 5. Značajnost razlika između skupina ispitanika (t-test za nezavisne uzorke)

mjera	<i>t</i>	<i>df</i>	<i>Sig.(2-tailed) = p</i>
BRR	-2,448	58	0,017
ORP	-0,193	58	0,847
MATTR	-1,224	58	0,226
D	-3,123	58	0,003
RJ_SOF	-1,283	58	0,205

Nakon računanja navedenih mjera rječničke raznolikosti i sofisticiranosti za svakog ispitanika te provedbe statističkih postupaka, rezultati pokazuju statistički značajnu razliku između skupine šestogodišnjaka i osmogodišnjaka na varijabli ukupnog broja različitih riječi (BRR) te statističku značajnu razliku na varijabli koja označava indeks rječničke raznolikosti D. Na preostale dvije varijable, tj. mjere rječničke raznolikosti, kao ni na varijabli rječničke sofisticiranosti nije dobivena statistički značajna razlika između skupina, iako osmogodišnjaci postižu više prosječne rezultate na svim navedenim varijablama. Prosječni rezultati za obje skupine na svim varijablama prikazani su na Slici 2.



Slika 2. Prikaz i usporedba prosječnih rezultata na mjerama rječničke raznolikosti i sofisticiranosti za obje skupine ispitanika

5. RASPRAVA

Nakon računanja mjera rječničke raznolikosti i sofisticiranosti na jezičnim uzorcima pripovijedanja kod djece različite kronološke dobi, može se zaključiti kako su jedine statistički značajne razlike između skupina ispitanika dobivene na mjerama BRR i D.

Prva hipoteza koja glasi „Mjere rječničke raznolikosti koje ovise o duljini jezičnog uzorka (BRR i ORP) razlikovat će djecu različite kronološke dobi“ - ne može se u potpunosti prihvatiti jer je statistički značajna razlika između dvije skupine ispitanika dobivena samo na mjeri ukupnog broja različitih riječi (BRR). U ovom je istraživanju dobiveno kako starija skupina ispitanika, osmogodišnjaci, upotrebljavaju statistički značajno više različitih riječi od mlađe skupine, šestogodišnjaka. Rezultat je u skladu s navodima Millera (1991) koji navodi porast mjere BRR s kronološkom dobi te je predstavlja kao bolji pokazatelj semantičkog razvoja nego što je to mjera ORP. Autor je u svom istraživanju provedenom na 192 djece urednog jezično-govornog razvoja htio odrediti postoji li povezanost mjera ukupnog broja riječi (UBR) i ukupnog broja različitih riječi (BRR) s porastom prosječne duljine iskaza te kronološkom dobi. Njegovi rezultati pokazuju kako obje mjere, UBR i BRR, imaju veće vrijednosti s porastom kronološke dobi te kako obje mjere značajno pridonose predviđanju kronološke dobi koje se temelji na procjeni prosječne duljine iskaza, koja također raste s kronološkom dobi. Prema Milleru, svaka od navedenih mjera mjeri različito područje jezičnog znanja i kompetencije; prosječna duljina iskaza omogućuje procjenu sintaktičkih sposobnosti, BRR pruža uvid u rječničko znanje, dok se mjera UBR više odnosi na opće jezične sposobnosti nekog govornika, kao što su brzina govora, sposobnost formulacije iskaza te govorno-motorička zrelost. Primjenu mjere BRR u istraživanjima podupire i činjenica da se pomoću broja različitih riječi u iskazu uspješno mogu odijeliti djeca urednog i narušenog jezično-govornog razvoja (Watkins i sur., 1995; Klee, 1992), no samo ukoliko se broj različitih riječi za svaki uzorak računa na standardiziranom broju iskaza, odnosno na uzrocima jednake duljine. Uporaba različitih postupaka standardizacije duljine uzorka (kraćenje uzorka, uzimanje određenog dijela uzorka, nasumični odabir riječi) utječe na to koji će uzorak imati veći broj različitih riječi te na taj način onemogućava usporedbu rezultata istraživanja koja rabe različite postupke standardizacije (Malvern i sur., 2004). Jezični uzorci mogu se ujednačavati i na način da se ispitanicima da sličan zadatak (dva kontrolirana slikovna predloška za poticanje pripovijedanja) te se tako očekuje i sličan broj iskaza. Iako u ovom istraživanju nije korišten nijedan postupak standardizacije, upotreba sličnog slikovnog

predložka za poticanje pripovijedanja omogućuje usporedbu dobivenih rezultata s prijašnjim istraživanjima koja tvrde kako mjera BRR može dobro odijeliti djecu različite kronološke dobi (Miller, 1991; Klee, 1992).

Iako osmogodišnjaci postižu više prosječne rezultate na mjeri ORP, razlika između starije i mlađe skupine nije se pokazala statistički značajnom. Prema rezultatima istraživanja Templin (1957) koja je analizirala uzorke duljine 50 iskaza, a koje je kasnije obradio Miller (1981), vidljiv je slab porast u mjeri ORP s dobi djeteta, no gotovo uvijek se ta vrijednost kreće oko 0.5. Razlog tome je da porastom kronološke dobi djeca upotrebljavaju sve više riječi, kao i sve veći broj različitih riječi što utječe na gotovo konstantan brojčani iznos ovog omjera. Templin, na temelju rezultata svog istraživanja provedenog na uzorku od 480 djece u dobi od 3 do 8 godina, zaključuje kako je omjer različenica i pojavnica među ispitanicama vrlo sličan te ne odražava razlike u dobi, spolu i socioekonomskom statusu. Konstantnost ovog omjera ima i klinički značajnu implikaciju jer, ukoliko on iznosi manje od 0.5, to može biti pokazatelj narušenog jezično-govornog razvoja (Miller, 1981). Iako je mjera ORP prvobitno razvijena kako bi se izbjegla ovisnost o duljini uzorka kao što je to slučaj s mjerom BRR, ova mjera također ovisi o duljini uzorka na koji se primjenjuje. Više vrijednosti bit će dobivene iz kraćih uzoraka, dok će iz duljih uzoraka vrijednosti ORP-a biti manje (Malvern i sur., 2004). Hess i sur. (1989), analizirajući jezične uzorke starije djece u dobi od 9 do 12 godina, dobivaju značajne razlike u srednjim vrijednostima mjere ORP kad se primjenjuje na uzorcima različite duljine. O utjecaju duljine uzorka na mjeru ORP nalaze se podaci i u nekim novijim istraživanjima (Tommerdahl i Kilpatrick 2013, 2014). Kako bi se ORP mogao upotrebljavati za usporedbu rječničke raznolikosti među jezičnim uzorcima, potrebno je računati ga na jednakom broju pojavnica za svaki uzorak. Također, da bi odijelio djecu različite kronološke dobi te pokazao veće vrijednosti s porastom kronološke dobi, ORP bi se trebao računati na uzorcima izjednačenima po broju pojavnica (Klee, 1992). Naime, s porastom kronološke dobi raste i ekspresivni rječnik djece urednog jezično-govornog razvoja što dovodi do sve veće raznolikosti u njegovoj upotrebi. Uz to što u svojim iskazima upotrebljavaju sve veći broj riječi, starija djeca upotrebljavaju više sinonima i sve specifičnije riječi što smanjuje njihovo ponavljanje. Ukoliko se računa na taj način, ORP bi vrlo vjerojatno imao nešto više vrijednosti u starijim skupinama ispitanika jer to označava da starija djeca imaju bogatiji ekspresivni rječnik i veću raznolikost u njegovoj upotrebi, tj. veću rječničku raznolikost. Dodatno, u morfološki bogatim jezicima kao što je primjerice hrvatski; starija djeca će

koristiti sve više različitih oblika neke riječi te će imati veći broj različenica u svojim iskazima nego mlađa djeca što će se odraziti na više vrijednosti ORP-a.

Druga hipoteza koja glasi: „ Mjere rječničke raznolikosti koje ne ovise o duljini jezičnog uzorka (D i MATTR) razlikovat će djecu različite kronološke dobi“ - također se ne može u potpunosti prihvatiti jer je statistički značajna razlika između skupina dobivena samo na mjeri D. Dobiveni rezultati u skladu su s istraživanjima Owen i Leonard (2002), koje su analizirajući jezične uzorke djece duljine 100 i 250 riječi, dobile kako su vrijednosti mjere D uvijek značajno više u starijoj skupini ispitanika. Takvi rezultati autorice vode do zaključka kako mjera D može dobro prikazati promjene i napredak u jezičnom razvoju što u ovom slučaju nije posljedica većeg broja pojava u uzorcima starije djece. Indeks rječničke raznolikosti D nastao je upravo s ciljem kako bi se premostili nedostaci ovisnosti mjere ORP o duljini uzorka. S činjenicom da je mjera D puno manje ovisna o duljini uzorka nego što je to ORP slažu se brojni autori (Malvern i sur., 2004; McCarthy i Jarvis, 2007, 2010; Koizumi i In'nami, 2012). Iako McKee i sur. (2000) napominju kako nema dokaza da na računanje mjere D utječe veličina uzorka, tj. broj pojava, za pouzdane rezultate ove mjere potrebno je da uzorak na kojem se računa sadržava barem 50 pojava. Prema zadanim postavkama, softver za računanje mjere D unutar programa CLAN crta te uspoređuje ORP krivulju s onom dobivenom na uzorku 35-50 pojava zbog čega je potrebno da uzorak sadrži barem 50 pojava. U tom slučaju, svaka točka krivulje dobivena je nasumičnim odabirom dijelova uzorka bez zamjene (Malvern i sur., 2004). Kako u ovom istraživanju svi transkripti nisu sadržavali 50 pojava, uz upotrebu naredbe *vocd* bilo je potrebno dodati kod *+br* (engl. *sampling with replacement* - uzorkovanje sa zamjenom) koji je omogućio računanje mjere D i na transkriptima kraćim od 50 pojava. Iako su uzorci upotrijebljeni u ovom istraživanju puno manji nego oni u istraživanju Owen i Leonard, isti rezultati mogu upućivati na to da mjera D može pouzdano odvojiti djecu različite kronološke dobi. S time su u skladu i navodi Bernstein Ratner i MacWhinneyja (2010), koji su rabeći računalnu analizu jezičnih uzoraka u longitudinalnom praćenju velike skupine djece u dobi od 24 mjeseca nadalje, zaključili kako je mjera D bolji prediktor kronološke dobi nego što je to ORP.

Nadalje, razlike između skupina ispitanika na mjeri MATTR nisu statistički značajne. Premda je vidljiva tendencija postizanja nižih prosječnih rezultata u mlađoj skupini ispitanika, ona se nije pokazala značajnom. Jedna od mogućnosti jest da je razlika premala da bi je mjera zahvatila, zbog uskog okvira za izračunavanje MATTR-a ili kraćih uzoraka za analiziranje. U istraživanju je, zbog ograničenih duljina transkripata, u pomični okvir uzeto samo 10 riječi.

Covington i McFall (2010) navode kako je tako uzak okvir prikladan samo ako je cilj otkriti neposredno ponavljanje prethodnih riječi ili izraza povezanih s netečnom govornom produkcijom, a ne rječničku raznolikost, tj. oskudniji rječnik. Za pouzdanije rezultate ove mjere potreban je svakako dulji govorni uzorak, kao i širi okvir za izračunavanje MATTR-a. Kao što je već napomenuto, nema istraživanja o primjeni ove mjere u istraživanjima dječjeg jezika što onemogućava usporedbu dobivenih rezultata s onima iz literature. Prijašnja istraživanja ove mjere poprilično su oskudna i najviše su vezana za jezik odraslih govornika. O pouzdanosti i valjanosti ove mjere govore jedino Fergadiotis i sur. (2013, 2015) koji tvrde kako je mjera dobar pokazatelj rječničke raznolikosti. Navedeni autori primjenjivali su i računali ovu mjeru na jezičnim uzorcima pripovijedanja osoba urednog jezičnog razvoja i osoba s narušenim jezičnim sposobnostima, osoba s afazijom, kako bi ukazali na njezine prednosti i jednostavnost primjene te nastojali potaknuti više istraživača da je upotrebljavaju u istraživanjima vezanim uz rječničku raznolikost.

Treća hipoteza koja glasi: „Mjera rječničke sofisticiranosti razlikovat će djecu različite kronološke dobi“ ne može se prihvatiti jer između mlađe i starije skupine ispitanika nije dobivena statistički značajna razlika na mjeri rječničke sofisticiranosti. Kako bismo analizirali ovakav rezultat, potrebno je nešto dublje poznavati kako teče razvoj rječnika. Rječničko znanje dobro je očuvano tijekom cijelog života, a umjeren porast u veličini rječnika vidljiv je čak do čovjekovih 60-tih godina (Wechsler, 1997). Ovo povećanje u rječničkom znanju u kontrastu je s očitim promjenama u sposobnosti pristupa leksičkim informacijama, a tome je dokaz postojanje značajnih teškoća u pronalaženju riječi što je posebice vidljivo u starijoj životnoj dobi (Kemper, 1992). Unatoč tim teškoćama, istraživanja su pokazala da se neki aspekti leksičke proizvodnje razvijaju te ostaju očuvani tijekom cijelog života. To se najbolje očitava u upotrebi raznolikijeg rječnika i većeg broja rjeđih riječi s porastom kronološke dobi (Kemper i Sumner, 2001). S time se slažu i Rabaglia i Salthouse (2011) koji navode da mjera rječničke sofisticiranosti u pripovjednom diskursu raste s dobi te kako je porast u upotrebi riječi koje imaju manju čestotnost povezana s općim rastom rječnika u odrasloj dobi. Prema svemu navedenom što je o razvoju rječnika u literaturi poznato, za očekivati je da će stariji ispitanici, u ovom slučaju osmogodišnjaci, imati širi rječnik te u pripovijedanju upotrebljavati specifičnije i riječi niže čestotnosti uporabe. Takva pretpostavka u ovom slučaju nije potvrđena jer se razlika između skupine šestogodišnjaka i osmogodišnjaka nije pokazala značajnom, iako je vidljiva tendencija postizanja viših prosječnih rezultata u starijoj skupini ispitanika. Razlog tome, osim vrste i duljine uzoraka na kojima su se mjere rječničke

sofisticiranosti računale, mogao bi biti i sam način računanja ove mjere. Kako bi se izračunala mjera rječničke sofisticiranosti, bilo je potrebno imati podatke o čestotnosti riječi u hrvatskom jeziku. U trenutku pisanja ovog rada Hrvatski čestotni rječnik dječjega jezika (*DjeČeR*) još nije bio objavljen, ali je bitno napomenuti da izrada i postojanje takvog rječnika mogu pružiti vrijedne podatke koji se mogu upotrebljavati kod računanja mjere rječničke sofisticiranosti. Za potrebe ovog diplomskog rada bilo je potrebno izraditi posebnu listu riječi na kojoj su se nalazile sve natuknice čije su se različnice u transkriptima pojavile do 10 puta. U svakom je transkriptu bilo potrebno izbrojati koliko se natuknica u njemu nalazi te koje od njih pripadaju navedenom popisu rijetkih. Kao konačan brojčani rezultat mjere uzet je omjer rijetkih natuknica i ukupnog broj natuknica. Omjer se kretao u rasponu od 0,63 do 0,86 što pokazuje da su ispitanici u svom pripovijedanju upotrebljavali poprilično puno rijetkih natuknica (63-86%). Takav rezultat upućuje na moguću neprikladnost načina mjerenja koja može biti posljedica toga da je prilikom izrade čestotnog rječnika svaka različnica koja se pojavila do 10 puta bila lematizirana, a kasnije su u transkriptima prebrojavane sve različnice neke natuknice koja bi se nalazila na popisu pa čak i one različnice koje su se u transkriptima pojavile više od 10 puta (jer je natuknica kojoj pripadaju bila na popisu rijetkih). Utjecaj na rezultate mogao je imati i efekt istozvučnosti jer su često dvije obličnice koje predstavljaju različit gramatički sadržaj (npr. oblik „sam“ kao 1. l. Sg. glagola biti i oblik „sam“ kao N/A Sg. pridjeva) predstavljale istu različnicu. Da su u istraživanju bili dostupni morfološki označeni podatci, bilo bi moguće prepoznati ovakve slučajeve i pridružiti oblik odgovarajućoj natuknici. Moguće je da bi postotak rijetkih natuknica bio drugačiji i da se gledao manji broj riječi (npr. natuknice koje su se pojavile do 5 puta) ili da su u obzir uzete samo punoznačne riječi. Vidljivo je da metodološka ograničenja računanja ove mjere smanjuju pouzdanost dobivenih rezultata, a problem, uz kratkoću korištenih uzoraka, predstavlja i činjenica da ne postoji jedinstvena procedura izračuna ove mjere.

Istraživanja rječničke sofisticiranosti većinom su usmjerena na proučavanje dvojezičnosti te se više temelje na pisanim uzorcima. Kako je već ranije spomenuto, u istraživanjima engleskog jezika za procjenu rječničke sofisticiranosti najviše se koristi Profil čestotnosti rječnika. Laufer i Nation (1995) ističu kako on ima dobru povezanost s drugim rječničkim mjerama, može odijeliti govornike različitih razina jezične kompetencije te je relativno stabilna mjera kad se gleda u različitim uzorcima iste osobe. Kako bi olakšali računanje rječničke sofisticiranosti i omogućili istraživačima lakšu i bržu analizu pisanih uzoraka, Kyle i Crossley (2015) osmislili su računalni Alat za automatsku analizu rječničke sofisticiranosti

(engl. *Tool for the Automatic Analysis of Lexical Sophistication*, TAALES) koji omogućava računanje čestotnosti svake riječi uzorka, ali i daje brojne druge semantičke te psiholingvističke podatke o pojedinoj riječi. Analizu riječi unutar programa omogućavaju podaci dobiveni iz posebnih korpusa i lista riječi za engleski jezik; *Corpus of Contemporary American English* (COCA; Davies, 2008), *Academic Word List* (AWL; Coxhead, 2000) te *Academic Formulas List* (AFL; Simpson-Vlach i Ellis, 2010) (Kyle, Crossley i Berger, 2017). Pregledom literature vidljivo je da u drugim jezicima istraživači imaju veću tendenciju istraživanja mjera rječničke raznolikosti nego sofisticiranosti jer to ne zahtjeva postojanje posebnih popisa s riječima osnovnog i naprednog vokabulara, ali i zbog same nedostupnosti programa i alata za automatsko računanje čestotnosti riječi poput onih dostupnih za engleski. Engleski se jezik tipološki razlikuje od morfološki bogatih jezika te se zbog toga kod drugih jezika javljaju brojni problemi s računanjem mjere rječničke sofisticiranosti. Primjerice, u hrvatskom jeziku svaka riječ ima brojne nastavke (morfeme) i oblike koji određuju njezino značenje, dok je u engleskom takvih nastavaka puno manje. Takva tipološka razlika onemogućava izravno prenošenje mehanizama računanja ove mjere u druge jezike, stoga je potrebno doraditi ih kako bi bili odgovarajući i za ostale jezike. Izvori koji se upotrebljavaju u ovakvim računalnim alatima morfološki su označeni. Danas u svijetu postoje precizni alati za automatsku lematizaciju i morfološko označavanje, a dostupni su i za hrvatski jezik (Agić, Ljubešić i Merkle, 2013; Ljubešić, Klubička, Agić i Jazbec, 2016). Problem predstavlja to što su ti alati razvijeni za posebne vrste korpusa, posebice za pisane korpusa pa nisu izravno primjenjivi na govoreni jezik općenito kao ni na dječji jezik. Danas u hrvatskom imamo nekoliko korpusa koji su javno dostupni i lematizirani pomoću takvih alata (Hrvatski nacionalni korpus, Hrvatski mrežni korpus, Jezična riznica). Ukoliko bi se razvio takav alat za dječji govoreni jezik, bilo bi puno jednostavnije i pouzdanije izračunati mjeru rječničke sofisticiranosti koja bi možda bolje mogla odraziti razlike među djecom različite kronološke dobi od onih dobivenih ovim radom. Kako bi se mjera rječničke sofisticiranosti više upotrebljavala i u istraživanjima drugih jezika, potrebno je potaknuti i istraživače u drugim jezicima na izradu/prilagodbu jedinstvenog programa koji bi na vrlo jednostavan način omogućio analizu podataka o čestotnosti uporabe pojedinih riječi.

6. OGRANIČENJA ISTRAŽIVANJA

Prilikom interpretacije rezultata ovog istraživanja važno je uzeti u obzir nekoliko njegovih ograničenja. Prvo, uzorak u istraživanju je relativno mali, što ograničava mogućnost generalizacije rezultata. Rezultati dosadašnjih istraživanja mjera rječničke raznolikosti i sofisticiranosti nisu potpuno jednoznačni, stoga bi veći uzorak ispitanika omogućio pouzdanije statističke analize podataka o njihovim jezičnim sposobnostima s naglaskom na rječničke sposobnosti. Drugi mogući nedostatak ovog istraživanja jest sama duljina upotrijebljenih uzoraka. Kao što je spomenuto u raspravi, utjecaj na utvrđivanje razlika između skupina ispitanika mogli su imati određeni nedostaci mjera rječničke raznolikosti, kao i prilagodbe kod izračunavanja tih mjera. Adekvatno određenje mjera rječničke raznolikosti zahtjeva određenu duljinu govornih uzoraka, a taj uvjeti nisu zadovoljili uzorci pojedinih ispitanika u ovom istraživanju. U računanju mjere D tako je bilo potrebno napraviti modifikacije u smislu uporabe dodatnog koda zbog nedovoljne duljine nekih uzoraka za koju autori smatraju da smanjuje pouzdanost rezultata (Malvern i sur., 2004; McCarthy i Jarvis 2007, 2010). Dulji uzorci pripovjednih diskursa svakako bi omogućili pouzdanije određenje mjera rječničke raznolikosti. Treće ograničenje odnosi se na samu metodologiju prikupljanja i transkripcije podataka. Kako su uzorci upotrijebljeni u ovom istraživanju prikupljeni unutar dva različita projekta, u prikupljanju, transkripciji i kodiranju sudjelovali su različiti ljudi - profesori, logopedi u školi, asistenti i studenti. Nažalost, podatci koji bi omogućili procjenu pouzdanosti procjenjivača, to jest podudarnost transkriptora nisu dostupni te je moguće da postoje određene nesustavnosti. Četvrto, metodološka ograničenja, posebice kod računanja mjera rječničke sofisticiranosti, uvjetovana su nedostatkom istraživanja ovih mjera u hrvatskom jeziku. Pouzdanost izračunavanja mjera rječničke raznolikosti i sofisticiranosti u hrvatskom jeziku nije provjerena, stoga je potrebno dobivene rezultate provjeriti u budućim istraživanjima koja bi uključivala veći uzorak ispitanika i dulje pripovjedne tekstove. Uz praćenje promjena vezanih uz porast kronološke dobi potrebno je uzeti u obzir i moguće individualne razlike među ispitanicima zbog činjenice da razlike u jezičnom (pa tako i leksičkom) razvoju između pojedinaca mogu biti izrazite.

7. ZAKLJUČAK

Iako brojni istraživači i stručnjaci nastoje istražiti jezični razvoj pomoću mjera rječničke raznolikosti, rezultati provedenih istraživanja često ne pokazuju jednoznačne rezultate. U ovom je istraživanju ispitana izvedba mlađe i starije djece na zadatku pripovijedanja kako bi se istražilo mogu li mjere rječničke raznolikosti i sofisticiranosti razlikovati djecu različite kronološke dobi. Rezultati su pokazali da se mlađa i starija skupina ispitanika statistički značajno razlikuju na mjerama BRR i D, dok na mjerama ORP, MATTR i mjeri rječničke sofisticiranosti nije dobivena značajna razlika, iako stariji ispitanici ostvaruju više srednje rezultate na svima. U ovom su istraživanju upotrijebljene različite mjere rječničke raznolikosti od kojih neke imaju nedostatke i njihova pouzdanost nije provjerena za hrvatski jezik pa navedeni rezultati ne omogućavaju opravdano donošenje zaključaka, ali pokazuju u smjeru moguće manje rječničke raznolikosti kod mlađe djece.

Rezultati ovog i drugih istraživanja o rječničkoj raznolikosti važni su zbog toga što se mjere rječničke raznolikosti sve više koriste u brojnim područjima, stoga je njihova validacija nužno potrebna. S logopedskog gledišta, posebno su korisne u procjeni rječnika dvojezične djece koju je potrebno vršiti u oba jezika. Takva procjena logopedima predstavlja pravi izazov, a razlog tome je nedostatak standardiziranih testova te nedostatak istraživanja o ranom razvoju rječnika dvojezične djece. U tom se slučaju logopedi mogu poslužiti govornim i pisanim uzorcima dječjeg jezika na kojima mogu izračunati mjere rječničke raznolikosti te usporediti rječničko znanje djece u svakom od jezika. Mjere rječničke raznolikosti u logopediji mogu služiti i kao nadopuna procjeni rječnika standardiziranim testovima. Ukoliko se računaju na jezičnim uzorcima spontanog govora ili pripovijedanja, mjere daju podatke o znanju i upotrebi riječi u prirodnim uvjetima što im daje prednost nad standardiziranim testovima. Mjere rječničke raznolikosti mogu se upotrebljavati i u procjeni prilikom sumnje na jezične teškoće. Istraživanja upućuju na to kako neke mjere, kao što je to primjerice BRR, mogu uspješno odijeliti djecu urednog jezičnog razvoja od njihovih vršnjaka s razvojnim jezičnim poremećajem (Klee, 1992; Watkins i sur., 1995).

Rezultati ovog rada mogu, barem djelomično, govoriti u prilog postavljenom cilju te upućuju na potrebu daljnjih istraživanja područja rječničke raznolikosti u hrvatskom jeziku. S obzirom da je ovo tek drugi rad vezan uz mjere rječničke raznolikosti i sofisticiranosti u hrvatskom

jeziku, potrebno je posebno naglasiti važnost ovog područja u proučavanju jezika te potaknuti istraživače na daljnja istraživanja i validaciju navedenih mjera.

8. POPIS LITERATURE

Agić, Ž., Ljubešić, N., Merkle, D. (2013). Lemmatization and Morphosyntactic Tagging of Croatian and Serbian. U *Proceedings of the 4th Biennial International Workshop on Balto-Slavic Natural Language Processing (BSNLP 2013)*, (str. 48–57). Sofija: Association for Computational Linguistics.

Arnaud, P. J. (1984). The Lexical Richness of L2 Written Productions and the Validity of Vocabulary Tests. U *Practice and Problems in Language Testing. International Symposium on Language Testin*, (str. 14-28). Colchester.

Bernstein Ratner, N., MacWhinney, B. (2016). Your laptop to the rescue: Using the child language data exchange system archive and CLAN utilities to improve language sample analysis. *Seminars in Speech and Language*, 37, 74-84.

Biber, D. (1988). *Variation across Speech and Writing*. Cambridge: Cambridge University Press.

Covington, M. A. (2007). *MATTR user manual CASPR research report 2007-05*. Atena: GA.

Covington, M. A., McFall, J. D. (2010). Cutting the Gordian knot: The moving-average type–token ratio MATTR. *Journal of Quantitative Linguistics*, 172, 94-100.

Coxhead, A. (2000). A new academic word list. *TESOL Quarterly*, 34 (2), 213-238.

Davies, M. (2008). *The Corpus of Contemporary American English: 450 million words, 1990-present*. <http://corpus.byu.edu/coca/>.

Demir-Vegter, S., Aarts, R., Kurvers, J. (2014). Lexical Richness in Maternal Input and Vocabulary Development of Turkish Preschoolers in the Netherlands. *Journal of Psycholinguistic Research*, 43(2), 149–165.

Fergadiotis, G., Wright, H. H., West, T. M. (2013). Measuring lexical diversity in narrative discourse of people with aphasia. *American Journal of Speech-Language Pathology*, 22, 397-408.

Fergadiotis, G., Wright, H., Green, S. (2015). Psychometric evaluation of lexical diversity indices: Assessing length effects. *Journal of Speech, Language, and Hearing Research* 58(3), 840.

Gagarina, N., Klop, D., Kunnari, S., Tantele, K., Välimaa, T., Balciuniene, I., Bognacker, U., Walters, J. (2012). *MAIN Multilingual Assessment Instrument for Narratives (Manual)*. Berlin: ZASPiL 56.

Gagarina, N., Klop, D., Kunnari, S., Tantele, K., Välimaa, T., Balciuniene, I., Bognacker, U., Walters, J. (2012). *MAIN Multilingual Assessment Instrument for Narratives*. Berlin: ZASPiL 56.

Hamers, J., Blanc M. (2000). *Bilinguality and Bilingualism: 2nd ed.*, Cambridge: Cambridge University Press.

Hess, C. W., Haug, H. T., Landry, R. G. (1989). The reliability of type-token ratios for the oral language of school age children. *Journal of Speech and Hearing Research*, 32, 536-540.

Hess, C. W., Ritchie, K. P., Landry, R. G. (1984). The type-token ratio and vocabulary performance. *Psychological Reports*, 55, 51-57.

Hoerning, H., Retherford, K. (2006). *Type-Token Ratio Scores: Establishing Norms for Preschool-Aged Children* [PowerPoint prezentacija]. Preuzeto s <http://asha.org/> (6.5.2019.)

Hoff, E. (2001). *Language Development*. Belmont: Wadsworth.

Hržica, G., Kuvač Kraljević, J. (2012). Croatian Multilingual Assessment Instrument for Narratives. U Gagarina, N., Klop, D., Kunnari, S., Tantele, K., Välimaa, T., Balčiūnienė, I., Bognacker (Ur.), *MAIN: Multilingual Assessment Instrument for Narratives*, (str. 201-218). Berlin: ZASPiL 56.

Hržica, G., Kuvač Kraljević, J., Šnajder, J. (2013). Hrvatski čestotni rječnik dječjega jezika. *Lahor*, 2(16), 189-205.

Jarvis, S. (2002). Short texts, best-fitting curves and new measures of lexical diversity. *Language Testing*, 19(1), 57–84.

- Jelaska, Z. (2005). Oblici hrvatskih riječi. U Jelaska, Z. i sur. (Ur.), *Hrvatski kao drugi i strani jezik*, (str.136-143). Zagreb: Hrvatska sveučilišna naklada.
- Johansson, V. (2008). Lexical diversity and lexical density in speech and writing: a developmental perspective. Working Papers 53, 61-79. Lund University, Department of Linguistics and Phonetics.
- Jones, R., Tschirner, E. (2006). *A frequency dictionary of German*. London: Routledge.
- Kelić, M., Hržica, G., Kuvač Kraljević, J. (2012). Mjere jezičnog razvoja kao klinički pokazatelji posebnih jezičnih teškoća. *Hrvatska revija za rehabilitacijska istraživanja*, 48(2), 23-40.
- Kemper, S. (1992). Adults' sentence fragments: Who, what, when, where, and why. *Communication Research*, 19, 444-458.
- Kemper, S., Sumner, A. (2001). The structure of verbal abilities in young and older adults. *Psychology and Aging*, 16, 312-322.
- Kilgarriff, A., Baisa, V., Bušta, J., Jakubíček, M., Kovář, V., Michelfeit, J., Rychlý, P., Suchomel, V. (2014). The Sketch Engine: ten years on. *Lexicography*, 1, 7-36.
- Klee, T. (1992). Developmental and diagnostic characteristics of quantitative measures of children's language production. *Topics in Language Disorders*, 12, 28-41.
- Koizumi, R., In'nami, Y. (2012). Effects of text length on lexical diversity measures: using short texts with less than 200 tokens. *System*, 40, 522-532.
- Kuvač, J., Palmović, M. (2007). *Metodologija istraživanja dječjega jezika*. Jastrebarsko: Naklada Slap.
- Kyle, K., Crossley, S. A. (2015). Automatically assessing lexical sophistication: Indices, tools, findings, and application. *TESOL Quarterly*, 49, 757-786.
- Kyle, K., Crossley, S., Berger, C. (2017). The tool for the automatic analysis of lexical sophistication (TAALES): version 2.0. *Behavior Research Methods*, 50(3), 1030-1046.
- Laufer, B. (1990). Ease and difficulty in vocabulary learning: Some teaching implications. *Foreign Language Annals*, 23(2), 147-155.

Laufer, B. (2003). Vocabulary Acquisition in a Second Language: Do Learners Really Acquire Most Vocabulary by Reading? Some Empirical Evidence. *Canadian Modern Language Review*, 59(4), 567–587.

Laufer, B., Nation, P. (1995). Vocabulary Size and Use: Lexical Richness in L2 Written Production. *Applied Linguistics*, 16(3), 307-322.

Libben, G., Jarema, G. (2002). Mental lexicon research in the new millennium. *Brain and Language*, 81, 1-10.

Lindqvist, C., Gudmundson, A., Bardel, C. (2013). A new approach to measuring lexical sophistication in L2 oral production. U C. Bardel, C. Lindqvist, B. Laufer (Ur.), *L2 vocabulary acquisition, knowledge and use: New perspectives on assessment and corpus analysis*. (str. 109-126). Eurosla: Eurosla Monographs Series.

Linnarud, M. (1986). *Lexis in composition: A performance analysis of Swedish learners' written English* (Vol. 74). Lund: Gleerup.

Loban, W. (1966). *Language Ability: Grades Seven, Eight. And Nine*. Washington DC: Government Printing Office.

Ljubešić, N., Klubička, F., Agić, Ž., Jazbec, I.P. (2016). New Inflectional Lexicons and Training Corpora for Improved Morphosyntactic Annotation of Croatian and Serbian. U *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC 2016)*, (str. 4264-4270). Portorož: European Language Resources Association (ELRA).

MacWhinney, B. (2000). *The CHILDES Project. Tools for analyzing talk*. New York: Lawrence Erlbaum Associates.

Malvern, D. D., Richards, B. J. (1997). A new measure of lexical diversity. U A. Ryan i A. Wray (Ur.), *Evolving models of language, Papers from the Annual Meeting of the British Association of Applied Linguists*, (str. 58-71). Clevedon: Multilingual Matters.

Malvern, D.D., Richards, B.J., Chipere, N., Dura'n, P. (2004). *Lexical diversity and language development: Quantification and assessment*. Hampshire: Palgrave Macmillan.

- McCarthy, P. M. (2005). *An assessment of the range and usefulness of lexical diversity measures and the potential of the measure of textual, lexical diversity MTL D*. Neobjavljeni doktorski rad. Memphis: University of Memphis.
- McCarthy, P. M., Jarvis, S. (2007). Vocd: A theoretical and empirical evaluation. *Language Testing*, 244, 459-488.
- McCarthy, P. M., Jarvis, S. (2010). MTL D, vocd-D, and HD-D: A validation study of sophisticated approaches to lexical diversity assessment. *Behavior Research Methods*, 42(2), 381–392.
- McKee, G., Malvern, D., Richards, B. (2000). Measuring vocabulary diversity using dedicated software. *Literary and Linguistic Computing*, 153, 323-337.
- Miličić, S., Kuvač Kraljević, J., Lenček, M. (2017). Leksička analiza početnica. *Logopedija*, 7 (1), 30-37.
- Miller, J. F. (1991). Quantifying productive language disorders. U J.F. Miller (Ur.), *Research on child language disorders: A decade of progress*, (str. 211-220). Austin: Pro-Ed.
- Nation, I.S.P. (1990). *Teaching and learning vocabulary*. New York: Heinle & Heinle.
- Olujić, M., Matić, A. (2017). Govorni i pisani jezik odraslih: koliko se razlikuju?. *Govor*, 34 (1), 33-52.
- Owen, A. J., Leonard, L. B. (2002). Lexical Diversity in the Spontaneous Speech of Children With Specific Language Impairment. *Journal of Speech Language and Hearing Research*, 45(5), 927.
- Palfreyman, D. M., Karaki, S. (2017). Lexical sophistication across languages: a preliminary study of undergraduate writing in Arabic (L1) and English (L2). *International Journal of Bilingual Education and Bilingualism*, 1–24.
- Rabaglia, C. D., Salthouse, T. A. (2011). Natural and constrained language production as a function of age and cognitive abilities. *Language and Cognitive Processes*, 26(10), 1505–1531.

- Ravid, D. (2006). Semantic Development in Textual Contexts During the School Years: Noun Scale Analyses. *Journal of Child Language*, 33, 791–821.
- Read, J. (2000). *Assessing vocabulary*. Cambridge: Cambridge University Press.
- Schmid, H. (1994). Probabilistic part-of-speech tagging using decision trees. *International Conference on New Methods in Language Processing*. Manchester, UK.
- Schmid, H. (1995). Improvements in part-of-speech tagging with an application to German. *Proceedings of the ACL SIGDAT-Workshop*. Dublin, Irska.
- Scott, M. (2004). *WordSmith tools version 4*. Oxford: Oxford University Press.
- Simpson-Vlach, R., Ellis, N. C. (2010). An academic formulas list: New methods in phraseology research. *Applied Linguistics*, 31, 487–512.
- Skehan, P., Foster, P. (2012). Complexity, Accuracy, Fluency and Lexis in Task-based Performance. U A. Housen, F. Kuiken i I. Vedder (Ur.), *Dimensions of L2 Performance and Proficiency: Investigating Complexity, Accuracy and Fluency in SLA*, (str. 199–220). Amsterdam: Benjamins.
- Šišková, Z. (2012). Lexical Richness in EFL Students' Narratives. *University of Reading Language Studies Working Papers*, 4, 26–36.
- Templin M. C. (1957). *Certain language skills in children*. Minneapolis: University of Minnesota Press.
- Tidball, F., Treffers-Daller, J. (2008). Analysing lexical richness in French learner language: What frequency lists and teacher judgment can tell us about basic and advanced words. *French Language Studies*, 18(3), 299-313.
- Tommerdahl, J., Kilpatrick, C. D. (2013). Analysing frequency and temporal reliability of children's morphosyntactic production in spontaneous language samples of varying lengths. *Child Language Teaching and Therapy*, 29, 171-183.
- Tommerdahl, J., Kilpatrick, C. D. (2014). The reliability of morphological analyses in language samples. *Language Testing*, 31, 3-18.

Topal, I. (2018). *Razlike u pripovjednom diskursu odraslih govornika s obzirom na modalitet jezika*. Zagreb: Odsjek za logopediju Edukacijsko-rehabilitacijskog fakulteta.

Vermeer, A. (2000). Coming to grips with lexical richness in spontaneous speech data. *Language Testing*, 17(1), 65–83.

Watkins, R. V., Kelly, D. J., Harbers, H. M., Hollis, W. (1995). Measuring Children's Lexical Diversity: Differentiating Typical and Impaired Language Learners. *Journal of Speech Language and Hearing Research*, 38(6), 1349.

Wechsler, D. (1997). *Wechsler Adult Intelligence Scale - Third Edition*. San Antonio: The Psychological Corporation.

Yu, G. (2009). Lexical Diversity in Writing and Speaking Task Performances. *Applied Linguistics*, 31(2), 236–259.