

Jacek Kudara
Trier University, Department of Phonetics
kudara@uni-trier.de

Josip Jagodar
Odjel društveno-humanističkih znanosti Sveučilišta u Slavskom Brodu
jjagodar@unisb.hr

Kako izvorni govornici hrvatskoga jezika razumiju druge slavenske jezike? Istraživanje metodom praćenja pokreta oka

Ovaj rad predstavlja rezultate istraživanja čiji je cilj bio ispitivanje i razumijevanje rečenica na srodnim slavenskim jezicima od strane izvornih govornika hrvatskoga jezika metodom praćenja pokreta očiju. Budući da nitko od sudionika nije studirao prevoditeljski smjer ili slavensku lingvistiku, studija ilustrira učinke pasivne višejezičnosti. Sudionici su bili izloženi slušnim podražajima na bugarskom, češkom, poljskom i ruskom jeziku, popraćenim vizualnim prikazima. Analiza anticipacijskih pokreta očiju pokazala je kako izvorni govornici hrvatskoga jezika, slušajući rečenice na drugom slavenskom jeziku, usmjeravaju svoju pozornost na referentne objekte čim prepoznaju predikat rečenice. Nadalje, rezultati pokazuju značajno razumijevanje poljskog jezika kod izvornih govornika hrvatskoga jezika. Ovo istraživanje pruža dokaze o učincima utemeljenim na Shannonovoj teoriji informacije u pasivnoj višejezičnosti te raspravlja o ulozi fonetske sličnosti između percipiranog podražaja i njegovog ekvivalenta u mentalnom leksikonu slušatelja.

1. Uvod

Međusobno razumijevanje govornika blisko srodnih jezika temelji se na stupnju sličnosti jezika koji se koriste u komunikaciji. Takav fenomen ovisi o strukturnim svojstvima govornikovog L1 i percipiranog L2, kao i o njihovom zajedničkom fonološkom sastavu. Stoga razumijevanje govora iz blisko srodnog jezika ovisi o fonetskoj sličnosti i stupnju podudarnosti između percipirane fraze i njezinog ekvivalenta na materinjem jeziku slušatelja. Nadalje, informacijsko-teorijska funkcija iznenađenja (Shannon 1948; Hale 2001), eng. *surprisal*, koja odgovara naporu da se podatak obradi (Ankener i dr. 2018), može kvantificirati stupanj poteškoća u razu-

mijevanju među govornicima blisko srodnih jezika ili lokalnog govora, kada svaki govori vlastitim L1 (Kudara 2022a). Metoda *Visual World Paradigm* (VWP) omogućuje mjerenje razumijevanja jezika u stvarnom vremenu kroz anticipativne pokrete očiju (Kamide i dr. 2003; Tanenhaus i dr. 1995; Sekicki i Staudte 2018). U ovoj studiji korištena je VWP metoda praćenja pokreta oka (Duchowski 2017; Carter i Luke 2020) kako bi se istražio utjecaj fonetske udaljenosti i funkcije iznenađenja na razumijevanje rečenice u višejezičnom okruženju. Izvorni govornici hrvatskog jezika bili su izloženi četirima slavenskim jezicima – bugarskom, češkom, poljskom i ruskom.

Poznata je činjenica da se govornici genetski i tipološki srodnih jezika međusobno razumiju bez učenja i vježbanja drugog jezika. Ova se pojava tipično naziva pasivna višejezičnost, za razliku od aktivne višejezičnosti koja zahtjeva proces učenja i često upotrebu metaligvističkog vokabulara. Temeljnu pretpostavku za obradu govora i vizualnu obradu scene dao je Cooper (1974), koji je primijetio da su sudionicima, istovremeno izloženim govornim i vizualnim podražajima, pokreti očiju sinkronizirani s različitim jezičnim događajima koji se prenose u slušnom modalitetu. Ovo zapažanje postavilo je temelje za VWP i omogućilo ispitivanje koriste li sudionici predikat rečenice kako bi svoju pozornost preusmjerili na vizualni referent (Altmann i Kamide 1999). Anticipirajući pogledi na vizualnom polju koje referira na semantički bliski objekt, mjereni uz pomoć *eye tracker*a svjedoče o dobrom razumijevanju percipiranih elemenata (npr. razumijevanju predikata kad je anticipirajući pogled usmjeren na njegovu kolokaciju prikazanu kao izravni objekt u rečeničnom sustavu).

Naša studija predlaže proširenje takve paradigme na višejezično okruženje. Stoga je primjenom VWP metode moguće ispitati usmjeravaju li sudionici pozornost na vidno polje koje predstavlja izravni objekt rečenice iz blisko srodnog jezika, percipiran u auditivnom modalitetu. Pretpostavlja se da takav učinak mogu pojačati slični osnovni oblici glagola u oba jezika, mjereni međusobnom fonetskom srodnosti, kao i stupnjem (ne)očekivanosti poticaja.

Praćenje pokreta očiju u VWP–u pokazalo se kao važna metoda za praćenje razumijevanja jezika u stvarnom vremenu. Prethodne studije koje su koristile ovu metodologiju pokazale su blisku usklađenost između fiksacija i procjene leksičke aktivacije (Farris–Trimble i McMurray 2013; Kudara 2022a). Za našu studiju važno je da se pokazalo kako fonetska sličnost izaziva preusmjeravanje pažnje na referentni objekt (Alloppenna i dr. 1998). Prethodne studije metodom VWP o prepoznavanju izgovorene riječi, koja ne pripada izvornom jeziku, pokazala su veću leksičku konkurenciju za unos iste, ali i potvrdile jednosmjerni učinak razumijevanja, čak i kada se ispituju manje bliski jezici od onih koji su ovdje ispitani, poput nizozemskog i engleskog (Weber i Cutler 2004). U skladu s prethodnim istraživanjima koja su pokazala da iznenađenje nije određeno samo jezičnim kontekstom, dokazano je da se ono može pojačati i vizualnim okruženjem (Sekicki i Staudte 2018). Gore spomenute studije pokazuju da je VWP prikladna metoda za istraživanje referentne obra-

de posredovane glagolom (Altmann i Kamide 1999), zbog toga se može proširiti na scenarij višejezičnog razumijevanja. Prethodne su studije pokazale da su fonetska površinska struktura etimološki srodnih riječi i informacijsko–teorijska funkcija iznenađenja relevantni kvantifikatori razumijevanja u višejezičnoj interakciji, koja obuhvaća tipološki i genetski bliske jezike (Kudera 2022a). Štoviše, primjena informacijsko–teorijskog metodološkog aparata omogućava uvid u asimetrični karakter pasivne višejezičnosti među izvornim govornicima slavenskih jezika. Spominjana asimetričnost, kako su već dokazale prethodne studije (Gooskens i dr. 2017, 2018, 2021, Kudera 2022a.), osniva se na stupnju društvene izloženosti drugim jezicima i stavovima prema korisnicima drugih jezika te se razmatra na razini sociolingvističkih studija.

2. Ciljevi i hipoteze

Primarni cilj ovog istraživanja bio je proučiti razumijevanje rečenica iz srodnog slavenskog jezika u auditivnom modalitetu s vizualno poboljšanim okruženjem. Pretpostavlja se da se informacija ekstrahirana iz predikata, a koja dolazi iz blisko srodnog jezika, može se koristiti za usmjeravanje pokreta očiju na bilo koji vizualni objekt koji odgovara percipiranom predikatu. Stoga smo pretpostavili da je razumijevanje rečenice, mjereno učinkom anticipacije pogleda u postavci VWP–a, vođeno informacijsko–teorijskim pojmom funkcije iznenađenja kao i fonetskom distancom između odgovarajućih predikata u hrvatskom jeziku i jeziku korištenom za podražaj. Nadalje, ova studija pokušava rasvijetliti asimetrični karakter pasivne višejezičnosti (Kudera 2022a) među izvornim govornicima slavenskih jezika.

3. Metodologija

Osmišljena VWP studija uključivala je izvorne govornike hrvatskog jezika koji su bili izloženi četirima slavenskim jezicima. Precizna internetska kamera za praćenje oka i algoritam *Webgazer* (Papoutsaki i dr. 2016) korišteni su za procjenu pogleda i detekciju preferencija vidnog polja. Ispitanici su bili izloženi slušnim podražajima prikazanim istovremeno s vizualnom radnjom. Sudionici su bili upućeni da slušaju rečenice i gledaju slike. Zatim je dan zadatak koji uključuje odgovaranje na pitanje u njihovom materinskom jeziku u vezi s razumijevanjem strane rečenice. Na primjer nakon podražaja: *ona hoće piti sada sok* na stranom jeziku, slijedilo je pitanje na materinjem jeziku ispitanika: *hoće li ona piti sada kavu*. Ispitanici su obaviješteni da slike mogu pružiti pomoć u razumijevanju rečenice, stoga bi trebali obratiti pozornost na objekte prikazane na zaslonu. Nastavak ispitivanja pokrenut je nakon što je ispitanik snimio odgovor. Pokreti glave bili su neograničeni tijekom snimanja. Budući da sintaktička ograničenja mogu utjecati na razumijevanje rečenice u VWP postavci (Altmann i Kamide 1999), u ovom istraživanju podražaji su bili sastavljeni od fiksnih fraza, poznatih subjektima već nakon probne interakcije. Po-

stavljanje eksperimenta isključivalo je korištenje naslona za bradu, ali je poza glave praćena u pozadini. Za praćenje pomaka glave koristio se *Java script* (Papoutsaki i dr. 2018), baziran na osnovnim principima računalnog vida, koji najprije definira oblik lica, potom prati pomake ispitanika u odnosu na tlo u stvarnom vremenu.

Kako bi se osigurala kvaliteta podataka, nakon svake vizualne scene vodili su se intervali provjere odstupanja (Carter i Luke 2020). Cilj ovoga postupka bila je izmjera fiksacija na zaslonu ispitanika i eventualnog pogleda izvan okvira u kome su bila pokazana sva vizualna polja. U slučaju gubitka prethodno kalibrirane pozicije glave, sudionici su zamoljeni da prilagode položaj glave i ponovno kalibriraju uređaj za praćenje oka prije početka sljedećeg ispitivanja. Eksperiment je trajao oko 25 minuta, iako je duljina varirala ovisno o sposobnosti ispitanika da zadrže dosljedan položaj glave.

3.1. Mjerila

Fonetske udaljenosti između transkribiranih glagolskih parova izračunate su korištenjem ponderiranog prosjeka triju mjera koje izražavaju fonetsku različitost na razini riječi: različitost konsonantskih segmenata (0,5), različitost vokalnih segmenata (0,3) i različitost strukture sloga (0,2). Ova shema ponderiranja postavljena je prema hipotezi po kojoj su konsonanti najistaknutiji fonetski čimbenici za međusobno razumijevanje i mogu utjecati na razumijevanje srodnih oblika riječi u relativno većoj mjeri nego što to mogu razlike u rasporedu samoglasnika ili strukturi sloga (Kudera i dr. 2023). Fonetske razlike između pojedinačnih parova suglasnika ili samoglasnika izračunate su iz vektora koji predstavljaju fonološka distinktivna obilježja svakog segmenta. Posljednja komponenta kvantificira različitost strukture sloga dviju riječi izračunavanjem duljinski normalizirane Levenshteinove udaljenosti (Levenshtein 1966) IPA nizova kodiranih kao ‘C’ (suglasnik) i ‘V’ (samoglasnik). Odabrana metoda primjenjuje se u mnogim suvremenim studijama koje se odnose na automatsku detekciju etimološke ili morfološke jezgre te se često koristi u radovima o višejezičnoj komunikaciji i interkomprehensiji (Beijering i dr. 2018, Kudera 2022a, Stenger i dr. 2022, Mosbach i dr. 2021). Međutim, zbog visoke podudarnosti etimološki srodnih predikata, struktura sloga bila je uzeta samo kao ponderiran prosjek vrijednosti 0,2 (Kudera i dr. 2021). Detaljni podaci dobivene fonetske udaljenosti glagolskih parova nalaze se u repozitoriji podataka OSF (poglavlje 7. Dostupnost podataka).

Funkcija iznenađenja je informacijsko teorijska mjera koja kvantificira (ne) očekivanost određenog ishoda, mjerena u bitovima, obrnuto proporcionalna njezinoj vjerojatnosti (Shannon i Weaver 1949). Točnije, iznenađenje ili *surprisal* izračunava se kao negativni logaritam (po bazi 2) vjerojatnosti ishoda. Dakle, ishodi s većom vjerojatnošću daju niže vrijednosti iznenađenja, i obrnuto, manje vjerojatni ishodi donose veće iznenađenje. Savršeno predvidljiv ishod s vjerojatnošću 1,0 rezultira iznenađenjem jednakim nuli. Iznenađenje glagolskih parova mjereno je

prema *Word Adaptation Surprisal*–u (WAS), (Kudera i dr 2022b), danom u sljedećoj jednadžbi, primijenjenoj na usklađene fonetske transkripcije u IPA:


$$WAS = - \sum_{i=1}^n \log_2(p(\textit{stimulus}L1_i | \textit{stimulus}L2_i))$$

gdje p ($\textit{stimulus} L1_i$ $\textit{stimulus} L2_i$) predstavlja vjerojatnost i -tog fonetskog segmenta riječi na materinjem jeziku slušatelja s obzirom na njegov ekvivalent – $\textit{stimulus} L2_i$ na stranom jeziku. Tako se procjenjuje potpuno iznenađenje zvukova jedne riječi s obzirom na usklađene ekvivalente u drugoj riječi. Vjerojatnosti fonetske korespondencije između svakog para jezika izvučene su automatski iz parnih fonetskih poravnanja 434 srodna skupa u četiri jezika. Pokazalo se da WAS korelira s razumljivošću među slavenskim jezicima (Kudera 2022a) i može se tumačiti kao kvantifikacija napora obrade koji je potreban izvornom govorniku jednog jezika da bi razumio leksičke jedinice iz srodnog jezika. Kako bi se uzelo u obzir različite duljine riječi, vrijednosti WAS–a su normalizirane prema duljini predikata. Detaljni podaci dobivene funkcije iznenađenja nalaze se u repozitoriji podataka OSF (poglavlje 7. Dostupnost podataka).

3.2. Vizualno polje

Za svako vizualno polje unaprijed su definirana četiri područja interesa. Četiri slike prikazane su u kutovima zaslona veličine 150 x 150 piksela, jednako udaljene od središta zaslona. Središte zaslona prikazivalo je subjekt rečenice, djevojku. Djevojka na slici imala je zatvorene oči kako bi se izbjegla sugestija da ona pokazuje na bilo koje vidno polje. U slike nisu uključeni nikakvi drugi vizualni elementi kako bi se osigurala vizualna istaknutost prikazanog objekta (slika 1). Slike isječaka prikazivale su lako prepoznatljive imenice slične složenosti. Vizualno polje svakog objekta u sceni bilo je definirano njegovom krajnjom vanjskom konturom. Slike su kontrolirane prema vizualnoj složenosti, kvaliteti i veličini. Pokusi su nasumično raspoređeni za svaku sesiju snimanja, a slike su nasumično dodijeljene svakom kutu zaslona. Jedan odgovarajući objekt nasumično je postavljen na svaku vizualnu scenu. Na primjer, referentni objekt u poljskoj rečenici (1) *ona chce pić teraz sok* bio je jedini predmet koji se mogao piti (čaša soka) među prikazanim slikama.

(1) <i>Ona</i>	<i>chce</i>	<i>pić</i>	<i>teraz</i>	<i>sok</i>
She	want–3gs.PRES	drink.INV	now	juice–ACC:SG



Slika 1. Primjer vizualne scene tijekom percepcije rečenice *ona hoće piti sada sok* na četiri slavenska jezika.

3.3. Audio podražaji

Auditivni podražaji sastojali su se od fiksnih rečenica tipa SVO (subjekt–glagol–objekt) na četiri slavenska jezika. Glagoli i objekti odvojeni su dodatnom riječi *sada*. Intervali od kraja glagola do početka dodatne riječi i od kraja dodatne riječi do početka izravnog objekta izjednačeni su na 200 ms. Svi su glagoli bili prijelazni i s visokim stupnjem kolokacije sa svojim izravnim objektom. Zbog relativno fleksibilnog reda riječi u slavenskim jezicima, struktura podražaja s dodanom riječi ispred izravnog objekta zvučala je prirodno i nije narušavala nikakva sintaktička ograničenja. Audio uzorci stvoreni su sustavom TTS za svaki testirani jezik. Intonacija je ručno optimizirana kako bi se postigao prirodan zvuk u rečenicama koje su uključivale dvije kratke stanke. Intonacijski kontur bio je ručno adaptiran kako stanke ne bi utjecale na prirodni intonacijski oblik rečenice. Za manualnu korekciju osnovne frekvencije (F0) korišten je Praat (Boersma i Weenink 2022). Nakon modifikacije sve su snimke provjerene od strane izvornih govornika sva četiri jezika kako bi se osigurao prirodan intonacijski oblik rečenice. Takva shema segmentacije omogućila je izjednačavanje širine vremenskog prozora analiziranih pokreta očiju i fiksacija. U procjeni prirodnosti intonacijskog kontura sudjelovala su četiri izvorna govornika. Njihov je zadatak bio ocjena prirodnosti i razumljivosti sintetiziranog podražaja. Snimke koje nisu bile rangirane kao prirodne od strane svih izvornik govornika, izbačene su iz testirana. U testu su korišteni samo ženski glasovi.

3.4. Sudionici

Ukupno 25 izvornih govornika hrvatskoga jezika (u dobi od 19 do 51 godina) sudjelovalo je u istraživanju. Svi su sudionici izjavili da koriste hrvatski jezik u svakodnevnoj komunikaciji. Sudionici su izabrani putem *crowd-sourcing* platforme i plaćeni su za svoje sudjelovanje. Važno je napomenuti da ispitanici nisu prethodno prošli obuku iz slavistike, lingvistike ili prevođenja kako bi se istražila pojava pasivne višejezičnosti. Također, sudionici su se izjasnili da nisu imali znanje drugog slavenskog jezika te nisu bili izloženi jednom od istraživanih jezika. Sesije snimanja u kojima sudionici nisu završili cijelu sesiju, bilo zbog nagle promjene pozadinskog osvjetljenja ili zbog problema s držanjem poze, nisu analizirane (ukupno 1 sesija). Podaci dobiveni iz te sesije su odbačeni.

3.5. Eksperimentalna procedura

Prije eksperimenta, *eye tracker* je trebalo kalibrirati. U prvom koraku sudionici su zamoljeni da prilagode pozadinsko osvjetljenje i da se udobno smjeste kako bi definirali središnju pozu. Kalibracija je provedena višestrukim ponavljanjem projiciranja zaslona s fiksacijskim točkama (15 do 20) uz zadržavanje središnjeg položaja. Nakon što je kalibracija dovršena i mreža lica uspješno predmemorirana, sudionici su započeli test razumijevanja. Zadatak sudionika bio je odgovoriti na pitanje koje je uslijedilo neposredno nakon audio podražaja i pritisnuti tipku koja označava točan odgovor. Pitanja su bila postavljena na hrvatskom jeziku. Prije početka ispitivanja provedena je probna sesija. Tijekom ispitivanja sudionici su bili izloženi podražajima na materinjem jeziku kako bi se osiguralo dobro razumijevanje eksperimentalne postavke. Ako je bilo potrebno, točke za fiksiranje prikazane su nakon svake sesije, zajedno s kratkim postupkom rekalkibracije. Za kontrolu je korišteno izlaganje rečenicama na hrvatskom jeziku. U analizi je uzeto u obzir vrijeme do prve fiksacije (Duchowski 2017) izravnog objekta na vidnom polju. Fiksacije su analizirane u vremenskom odnosu s jezičnim događajima iz slušnih podražaja. Koordinate fiksacija (x/y) uspoređene su s vremenom prve fiksacije na ciljano vidno polje. Podaci koji se odnose na fiksacije na vizualnu metu prije reprodukcije verbalne komponente zvuka odbačeni su iz analize. Takve fiksacije označene su kao slučajne jer nisu potaknute informacijama koje nosi rečenični predikat koji još nije bio percipiran.

3.6. Analiza podataka

Analize su provedene korištenjem R (verzija 4.1.1; R Core Team 2021), korištenjem *zoo-metode* (verzija 1.8.9; Zeileis i Grothendieck 2005), *PerformanceAnalytics* paketa (verzija 2.0.4; Peterson i Carl 2020), *Matrix* metode strukturne analize (verzija 1.3.4; Bates i Maechler 2021), *lme4* paketa (verzija 1.1.27.1; Bates i dr. 2015), *xts* paketa (verzija 0.12.1; i Ulrich 2020), *Companion to Applied Regression* paketa (verzija 3.0.11; Fox i Weisberg 2019), *jtools* paketa (verzija 2.1.4; Long 2020), *sj-*

Plot paketa (verzija 2.8.9; Lüdecke 2021), *report* paketa (verzija 0.5 .1; Makowski i dr. 2020), *ggstatsplot*–a (verzija 0.9.0; Patil 2021.), *psych*–a (verzija 2.1.6; Revelle 2021), *rcompanion*–a (verzija 2.4.13; Mangiafico 2022). Statističkim testovima određena je razina značajnosti $\alpha = 0,05$.

3.7. Statističke metode

Koeficijenti korelacije između varijabli na kontinuiranoj skali izračunati su Pearsonovom metodom. Odnos dviju varijabli na nominalnoj skali analiziran je u parovima u obliku tablica kontingencije s naznakom učestalosti i udjela. Ovisnost varijabli ispitana je Pearsonovim hi–kvadrat testom s Cramerovom V–mjerom povezanosti. Linearna regresija (procijenjena pomoću OLS–a) korištena je kako bi se modelirao raznovrsni utjecaj eksplanatornih varijabli na vrijeme do faktora prvog pogleda. Durbin–Watson statistika korištena je kao test za provjeru autokorelacije u rezidualima statističke regresijske analize. Pretpostavke o autokorelaciji nezavisnih varijabli testirane su generaliziranim faktorima varijance–inflacije (VIF). Intervali pouzdanosti (95%–tni CI) i p–vrijednosti izračunati su pomoću Waldove aproksimacije. Testni uzorak sastojao se od 848 opažanja i sadržavao je šest varijabli. Tablica 1 predstavlja kratak opis varijabli u studiji.

Varijabla	Tip podataka	Raspon
Vrijeme do prve fiksacije na vizualnom polju	Kontinualni	$x \in \mathbb{R}^+$
Fonetska udaljenost	Kontinualni	$x \in \mathbb{R}^+$
Funkcija iznenađenja–Surprisal	Kontinualni	$x \in \mathbb{R}^+$
Odgovor	Kategorički	{True, False}
Jezik	Nominalni	{bg, cs, pl, ru}
ID–ispitanika	Ordinalni	[1–24]

Tablica 1. Opis varijabli

3.8. Analiza distribucije i srednje razlike

Proučavanje normalne distribucije kontinuiranih varijabli provedeno je pomoću Shapiro–Wilkovog testa. Pri tumačenju tipa distribucije varijabli u obzir su uzete i mjere asimetrije i zaobljenosti (*skewness & kurtosis*). Varijable s vrijednostima asimetrije nižim od 2,0 i vrijednostima zaobljenosti nižim od 7,0 tretirane su kao normalno raspodijeljene varijable (Curran i dr. 1996; Bandalos 2018; Fabrigar i dr. 1999; Wegener i Fabrigar 2000), inače je zaključak donesen s distribucijom različitom od normalne.

U slučaju da je grupa bilo više od dvije i da su kontinuirane varijable bile s normalnom distribucijom, korištena je Welchova jednosmjerna ANOVA analiza za neovisne uzorke ispitivanja srednjih vrijednosti s omegom na kvadrat kao mje-

rom veličine učinka. U slučaju dviju skupina i kontinuirane varijable s normalnom distribucijom, t–Welch analiza provedena je Hedgesom–g formulom (kao mjerom veličine učinka). Distribucija varijabli na kontinuiranoj skali zajedno s testom normalnosti distribucije prikazana je u tablici 2.

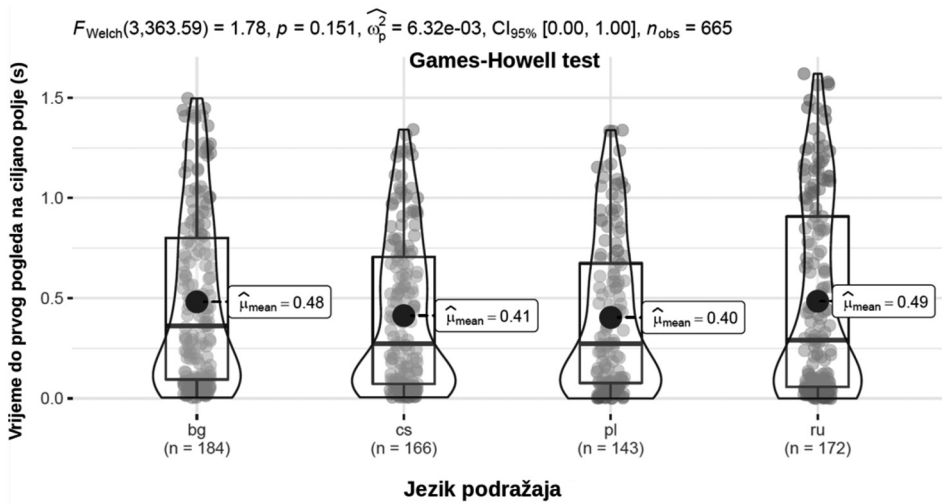
<i>Varijabla</i>	<i>n</i>	<i>M</i>	<i>SD</i>	<i>Mdn</i>	<i>Min</i>	<i>Max</i>	<i>Skew</i>	<i>Kurt</i>	<i>W</i>	<i>p</i>
Vrijeme do prve fiksacije na vizualnom polju	665	0.45	0.42	0.3	0	1.62	0.77	–0.61	0.87	<0.001
Fonetska udaljenost	848	0.35	0.10	0.33	0.12	0.52	0.04	–0.33	0.97	<0.001
Funkcija iznenađenja–Surprisal	848	6.12	1.81	6.19	2.53	2.53	–0.32	–0.63	0.96	<0.001

Tablica 2. Deskriptivna statistika – varijable (*n* – veličina uzoraka, *M* – sredina, *SD* – standardna devijacija, *Mdn* – medijan, *Min* – minimalna vrijednost, *Max* – maksimalna vrijednost, *Skew* – koeficijent asimetrije (Skewness), *Kurt* – eksces spljoštenosti (Kurtosis), *W* – Shapiro–Wilkov test, *p* – značajnost)

Od 848 odgovora koje su dali sudionici, varijabla rezultata sastojala se od 189 (22,3%) netočnih odgovora i 659 (77,8%) točnih odgovora. U slučaju varijable jezika podražaja, distribucija korištenih jezika bila je sljedeća: bugarski *n* = 225 (26,5%), češki *n* = 226 (26,7%), poljski *n* = 172 (20,3%) i ruski *n* = 225 (26,5%). Broj opažanja varirao je između sudionika i kretao se od 10 do 60 (*Mdn* = 30).

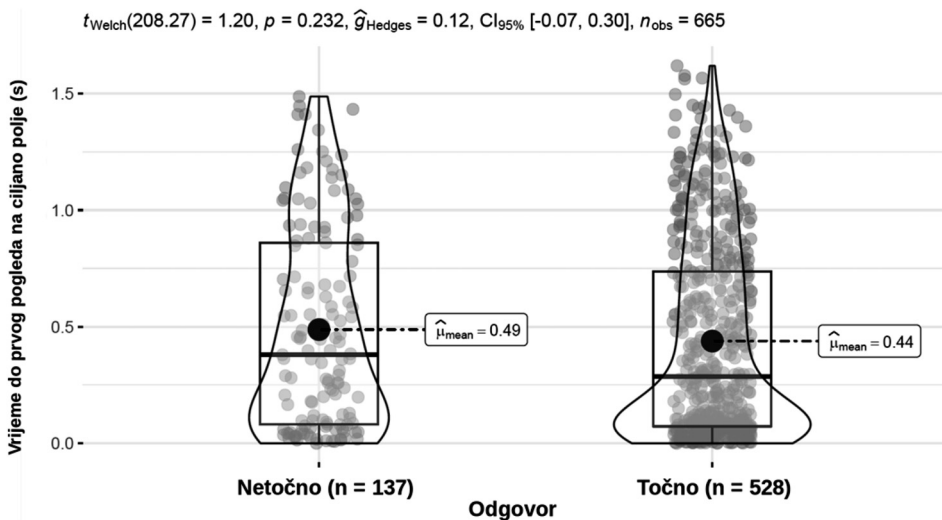
4. Rezultati

Iz podataka iz tablice 2 pokazalo se da asimetrija i zaobljenost za proučavanu varijablu nisu premašili granične vrijednosti te su se za testiranje hipoteza koristili parametarski testovi. Provedena Welchova jednosmjerna ANOVA analiza nije pokazala nikakve značajne razlike u vremenu kod varijable prvog pogleda između bugarskog (*M* = 0,48, *SD* = 0,43), češkog (*M* = 0,41, *SD* = 0,38), poljskog (*M* = 0,40, *SD* = 0,38) i ruskog (*M* = 0,49, *SD* = 0,48) jezičnog podražaja, *F*–Welch = (3, 363,59) = 1,78, *p* = 0,151, $\hat{w}_p^2 < 0,01$. Grafički prikaz statističkog testa prikazan je na slici 1.



Slika 1. Grafički prikaz utjecaja jezika rečenice na vrijeme do prve fiksacije na ciljano vizualnom polju (F–Welch – Welchova jednosmjerna ANOVA, $\hat{\omega}_p^2$ – učinkovitost efekta, p – značajnost, CI – interval pouzdanosti, n – veličina uzorka)

Provedeni *t–Welch* test nije pokazao značajne razlike u vremenu kod varijable prvog pogleda na ciljano vizualno polje između netočnih rezultata ($M = 0,49, SD = 0,43$) i točnih rezultata ($M = 0,44, SD = 0,42$), $t\text{-Welch} = (208,27) = 1,20, p = 0,232, \hat{g}_{\text{hedges}} = 0,12$). Grafički prikaz statističkog testa prikazan je na slici 2.



Slika 2. Grafički prikaz – kategorička varijabla (točnost odgovora) i vrijeme do prve fiksacije na ciljano vizualnom polju (t–Welch – t Welchov test, p – značajnost, \hat{g}_{hedges} – Hedgeova učinkovitost efekta, CI – interval pouzdanosti, n – veličina uzorka)

4.1. Korelacije

Provedena korelacijska analiza pokazala je blago pozitivan odnos između varijable vremena do prvog pogleda i fonetske udaljenosti s funkcijom iznenađenja. Pokazana je srednje značajna veza između vremena do prvog pogleda i fonetske udaljenosti ($r = 0,12$, $p < 0,01$), dok je značajnost između vremena do prvog pogleda i funkcije iznenađenja utvrđena na razini statističkog trenda ($r = 0,08$, $p < 0,1$).

4.2. Jezik stimulusa i točnost odgovora

Provedeni test neovisnosti pokazao je značajnu ovisnost proučavanih varijabli. Rezultati testa neovisnosti: $\chi^2 = 33,39$, $df = 3$, $V = 0,20$, $p < 0,001$. Distribucije varijabli prikazane su u tablici 3.

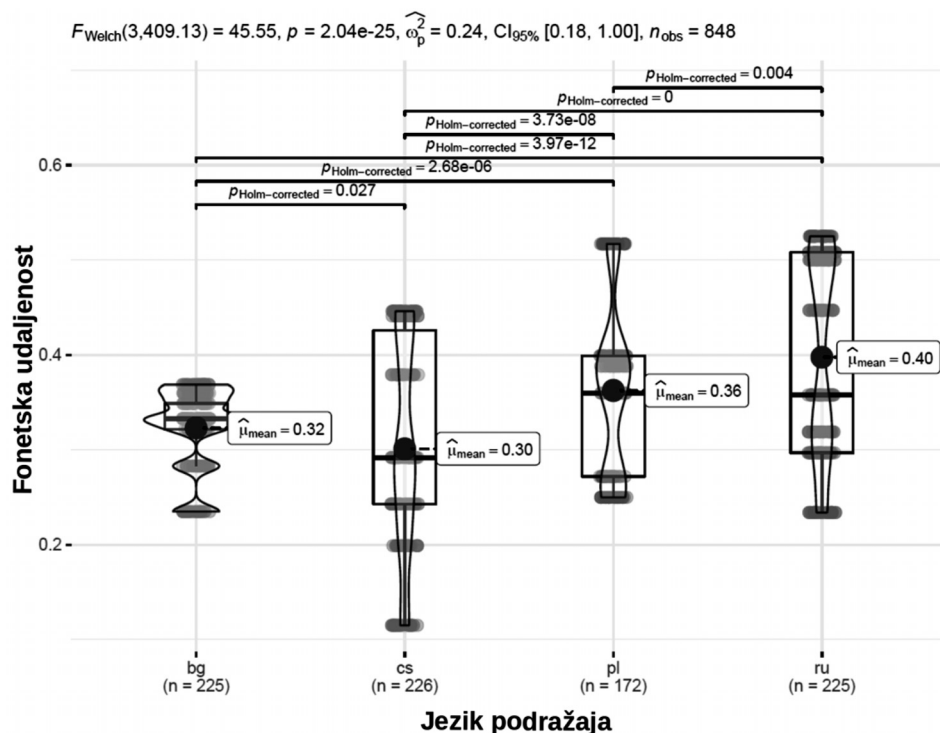
Jezik stimulusa	Odgovor		Ukupno
	Netočno	Točno	
bugarski	40 (17.8%)	185 (82.2%)	225
češki	39 (17.3%)	187 (82.7%)	226
poljski	29 (16.9%)	143 (83.1%)	172
ruski	81 (36%)	144 (64%)	225
<i>Ukupno</i>	189 (22.3%)	659 (77.7%)	848

Tablica 3. Distribucija testiranih varijabli

Provedeni post-hoc test pokazao je značajne razlike u varijabli rezultata između sljedećih parova jezika podražaja: bugarski naspram ruski ($p < 0,001$; $V = 0,21$), češki naspram ruski ($p < 0,001$; $V = 0,21$), poljski naspram ruski ($p < 0,001$; $V = 0,21$).

4.3 Jezična i fonetska distanca


Provedena Welchova jednosmjerna ANOVA analiza pokazala je značajne razlike u fonetskoj udaljenosti između svih parova podražajnih jezika: bugarski ($M = 0,32$, $SD = 0,04$), češki ($M = 0,41$, $SD = 0,11$, poljski ($M = 0,36$, $SD = 0,09$)) i ruski ($M = 0,40$, $SD = 0,10$), F -Welch (3, 409,13) = 45,55, $p < 0,001$, $\hat{w}_p^2 = 0,24$. Grafički prikaz statističkog testa prikazan je na slici 3.



Slika 3. Grafički prikaz fonetske distance između jezika stimulusa i hrvatskog (F–Welch – Welchova jednosmjerna ANOVA, $\hat{\omega}_p^2$ – učinkovitost efekta, p – značajnost, CI – interval pouzdanosti, n – veličina uzorka)

4.4. Jezik stimulusa i funkcija iznenađenja

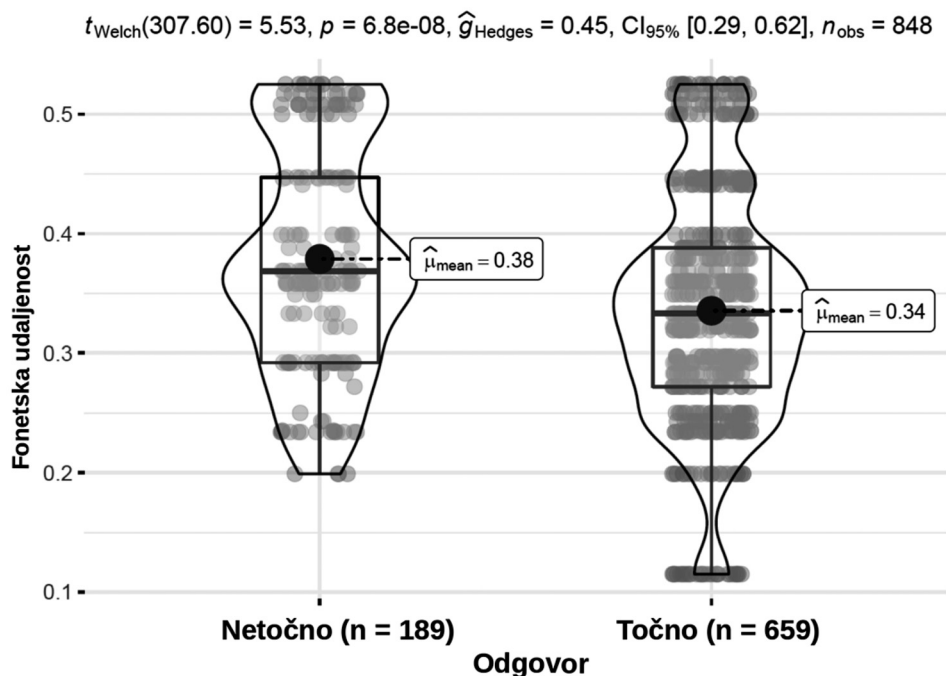
Provedena Welchova jednosmjerna ANOVA analiza pokazala je značajne razlike u iznenađenju između svih parova funkcije iznenađenja: bugarskog ($M = 5,64$, $SD = 1,78$), češkog ($M = 6,00$, $SD = 1,53$), poljskog ($M = 4,78$, $SD = 1,19$) i ruskog ($M = 7,75$, $SD = 1,12$) osim bugarskog u odnosu na češki, F–Welch ($3, 461, 28$) = 209,79, $p < 0,001$, $\hat{\omega}_p^2 = 0,57$. Grafički prikaz rezultata prikazan je na slici 4.



Slika 4. Grafički prikaz funkcije iznenađenja i jezika stimulusa (F–Welch – Welchova jednosmjerna ANOVA, $\hat{\omega}_p^2$ – učinkovitost efekta, p – značajnost, CI – interval pouzdanosti, n – veličina uzorka)

4.5. Točnost odgovora i fonetska udaljenost


Provedeni t–Welch test pokazao je značajne razlike u fonetskoj udaljenosti između netočnih rezultata ($M = 0,38, SD = 0,9$) i točnih rezultata ($M = 0,34, SD = 0,10$), t–Welch (307,60) = 5,53, $p < 0,001, \hat{g}_{\text{hedges}} = 0,45$. Grafički prikaz statističkog testa prikazan je na slici 5.



Slika 5. Grafički prikaz utjecaja fonetske udaljenosti na točnost odgovora (t Welch – t Welchov test, p – značajnost, \hat{g}_{hedges} – Hedgeova učinkovitost efekta, CI – interval pouzdanosti, n – veličina uzorka)

4.6. Rezultati i iznenađenje

Provedeni t–Welch test pokazao je značajne razlike u faktoru iznenađenja između netočnih rezultata ($M = 6,92, SD = 1,57$) i točnih rezultata ($M = 5,89, SD = 1,81$), t–Welch = (345,61) = 7,61, $p < 0,001, \hat{g}_{\text{hedges}} = 0,60$. Grafički prikaz statističkog testa prikazan je na slici 6.



Slika 6. Grafički prikaz utjecaja funkcije iznenađenja na točnost odgovora (t Welch – t Welchov test, p – značajnost, \hat{g}_{Hedges} – Hedgeova učinkovitost efekta, CI – interval pouzdanosti, n – veličina uzorka)

4.7. Analiza regresije

Cilj raznovrsne analize bio je istražiti značajnost raznovrsnost učinka proučavanih čimbenika na varijablu vremena do prvog pogleda na ciljano vizualnom polju. Primjena linearnog mješovitog modela (1) nije bila primjerena zbog vrijednosti unutar–razrednog koeficijenta korelacije između sudionika u slučaju osnovnog modela (ICC = 0,01) s minimalnom vrijednošću 0.2 za primjenu modela (1):

- (1) (vrijeme do prvog pogleda na ciljano polje ~ + 1 + (1 | ID sudionika), REML = FALSE)

Primjena višestruke linearne regresije pokazala je značajnost utjecaja dvaju čimbenika na zavisnu varijablu (2):

- (2) vrijeme do prvog pogleda na ciljano polje ~ Fonetska udaljenost + jezik podražaja

Prediktori	Vrijeme do prve fiksacije na ciljanom vizualnom polju		
	Procijena	CI – interval pouzdanosti	p
Odsječak	0.31	0.18 – 0.44	< 0.001
Fonetska udaljenost	0.54	0.19 – 0.89	0.003
Jezik stimulusa – češki	–0.06	–0.15 – 0.03	0.197
Jezik stimulusa – poljski	–0.10	–0.19 – 0.00	0.043
Jezik stimulusa – ruski	–0.03	–0.12 – 0.06	0.478

Tablica 4. Rezultati statističke analize

Model je imao niske VIF vrijednosti (< 2) za svaki prediktor. Durbin–Watsonov test nije bio značajan ($DW = 1,95$, $p = 0,604$) što dokazuje nedostatak autokorelacije. Ukupni rezultati, navedeni u tablici 4, pokazuju da: nije bilo značajnog učinka na zavisnu varijablu u korištenju češkog ili ruskog podražajnog jezika u usporedbi s referentnim jezikom; korištenje poljskog podražajnog jezika značajno je smanjilo vrijeme do prvog pogleda na 0,10 (pod uvjetom da nije došlo do promjene faktora fonetske udaljenosti); povećanje faktora fonetske udaljenosti za 1,0 povećat će zavisnu varijablu za 0,51.

5. Rasprava

U usporedbi sa studijama koje govore o izloženosti samo materinjem jeziku, ispitanici su pokazali da mogu identificirati predikat iz stranog, ali srodnog slavenskog jezika. Značaj učinka iznenađenja sugerira da razumijevanje blisko srodnih jezika može biti potaknuto primijenjenim mjerama kontekstualne (ne)očekivanosti i fonetske sličnosti (Kudera i dr. 2021). Budući da su i srodni i nesrodni glagolski parovi bili uključeni kao podražaji, sudionici su morali prvo prepoznati podražaje srodne riječima u njihovom materinskom jeziku. Stoga, snažan učinak iznenađenja proizlazi iz činjenice da je ono vjerojatno bolji prediktor srodnosti od same mjere fonetske udaljenosti. U ovome istraživanju razmatrana su dva čimbenika koja uvjetuju uspješno razumijevanje srodnog jezika. Razina izmjerene fonetske sličnosti između glagola istog etimološkog korijena obuhvaća niz dijakronijskih alternacija nastalih tijekom divergencije. Funkcija iznenađenja odnosi se na kognitivni proces obrade jezičnog podražaja koji potječe iz srodnog jezika. Ispostavilo se da ova dva faktora igraju važnu ulogu u uspješnoj receptivnoj višejezičnosti.

Nekoliko prethodnih studija pokazalo je da obrazac međusobnog razumijevanja samo u ograničenoj mjeri odražava tipološku podjelu slavenskih jezika (Kudera 2022a). Jaki učinci razumljivosti otkriveni su za jezične parove koji ne pripadaju istoj podskupini slavenskih jezika, stoga je zaključeno da su informacije primljene na razini glagola korištene za usmjeravanje pažnje na izravni objekt čak i u slučaju

izloženosti stranom jeziku. Zanimljivo opažanje odnosilo se na rečenice na poljskom koje su, čini se, potaknule pozornost izvornim govornicima hrvatskoga prema izravnom objektu brže nego u drugim testiranim jezicima što svjedoči o višem učinku međusobnog razumijevanja.

Kao svako instrumentalno istraživanje, primijenjena metodologija može se usavršavati npr. povećanjem stope uzorka u obradi analize pokreta oka ili uključivanjem varijabli proširenja zjenice u korelaciji s funkcijom iznenađenja. Osim toga, testiranje pasive višejezičnosti također se može provoditi drugačijim metodama. Na raspolaganju je, osim ovdje primijenjene metode praćenja pokreta oka, niz *offline* testova koji obuhvaćaju prijevod, interkomprehenziju govora i teksta itd.

6. Zaključci

U ovom istraživanju testirano je razumijevanje govornih podražaja iz stranog, ali srodnog jezika, u stvarnom vremenu u vizualnom okruženju. Prikupljeni podaci podržavaju hipotezu da je obrada rečenice na srodnom, ali nematerinskom jeziku, mjerena anticipacijskim pokretima očiju, vođena informacijsko–teoretskim pojmom iznenađenja mjenjenim na odgovarajućim predikatima. Podaci prikupljeni u ovoj studiji pokazali su da izvorni govornici hrvatskoga jezika mogu odmah uspostaviti ovisnost između predikata rečenice i njegovog izravnog objekta čak i ako rečenicu percipiraju na stranom ali srodnom jeziku. Nadalje, odnos između odgovarajućih predikata može se kvantificirati primijenjenim mjerama kontekstualne (ne)očekivanosti i fonetske sličnosti površinskih oblika predikata. Studija je pokazala da pružene informacije uspješno usmjeravaju pokrete očiju prema izravnom objektu u vizualnom okruženju koje zadovoljava glagolska ograničenja, to jest semantički i kolokacijski odgovara rečeničnom predikatu.

Nadalje, ovo je istraživanje pokazalo da razumijevanje predikata uzrokuje pomicanje pozornosti prema objektu prije početka referentne imenice. Zanimljivo opažanje odnosilo se na razumijevanje rečenica na poljskom za koje se činilo da izazivaju snažan pomak pažnje prema ciljnoj vizualnoj sceni. Takav rezultat ukazuje na usmjerenost i asimetričnost slavenskoga razumijevanja. Ovo je istraživanje također rasvijetlilo snažan učinak međusobne razumljivosti među govornicima slavenskih jezika.

7. Dostupnost podataka

Anonimizirani podaci dostupni su u *Open Science Framework* repozitoriju: <https://doi.org/10.17605/OSF.IO/JWFPU>

Bibliografija

- Allopenna, Paul, James S. Magnuson i Michael K. Tanenhaus (1998). Tracking the time course of spoken word recognition using eye movements: Evidence for continuous mapping models. *Journal of Memory and Language* 38(4): 419–439, <https://doi.org/10.1006/jmla.1997.2558>
- Altmann, Gerry i Yuki Kamide (1999). Incremental interpretation at verbs: Restricting the domain of subsequent reference. *Cognition* 73(3): 247–264, [https://doi.org/10.1016/S0010-0277\(99\)00059-1](https://doi.org/10.1016/S0010-0277(99)00059-1)
- Ankener, Christine, Mirjana Sekicki i Maria Staudte (2018). The influence of visual uncertainty on word surprisal and processing effort. *Frontiers in psychology* 9: 1–17, <https://doi.org/10.3389/fpsyg.2018.02387>
- Bandalos, Deborah (2018). *Measurement theory and applications for the social sciences*. The Guilford Press.
- Boersma, Paul i David Weenink (2021). *Praat: Doing phonetics by computer* v. 6.2.32, <https://www.fon.hum.uva.nl/praat/>.
- Carter, Benjamin i Steven Luke (2020). Best practices in eye tracking research. *International Journal of Psychophysiology* 155: 49–62, <https://doi.org/10.1016/j.ijpsycho.2020.05.010>
- Cooper, Roger (1974). The control of eye fixation by the meaning of spoken language: a new methodology for the real-time investigation of speech perception, memory, and language processing. *Cognitive psychology* 6(1): 84–107, [https://doi.org/10.1016/0010-0285\(74\)90005-X](https://doi.org/10.1016/0010-0285(74)90005-X)
- Curran, Patrick, Stephen West i John Finch (1996). The robustness of test statistics to non-normality and specification error in confirmatory factor analysis. *Psychological Methods* 1(1): 16–29, <https://doi.org/10.1037/1082-989X.1.1.16>
- Douglas Bates i Martin Maechler (2021). Matrix: Sparse and Dense Matrix Classes and Methods. R package version 1.3–4. <https://CRAN.R-project.org/package=Matrix>
- Douglas Bates, Martin Maechler, Ben Bolker i Steve Walker (2015). Fitting Linear Mixed-Effects Models Using lme4. *Journal of Statistical Software* 67(1): 1–48, <https://doi.org/10.48550/arXiv.1406.5823>
- Duchowski, Andrew (2017). *Eye tracking methodology: Theory and practice*. Springer, <https://doi.org/10.1007/978-3-319-57883-5>
- Fabrigar, Leandre, Duane Wegener, Robert MacCallum i Erin Strahan (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods* 4, 272–299, <https://doi.org/10.1037/1082-989X.4.3.272>
- Farris–Trimble, Ashley i Bob McMurray (2013). Test–retest reliability of eye tracking in the visual world paradigm for the study of real-time spoken word recognition. *Journal of Speech, Language, and Hearing Research* 56(4): 1328–1345, [https://doi.org/10.1044/1092-4388\(2012\)12-0145](https://doi.org/10.1044/1092-4388(2012)12-0145)
- Fox, John i Sanford Weisberg (2019). *An R Companion to Applied Regression*, Third Edition. Thousand Oaks CA: Sage. <https://socialsciences.mcmaster.ca/jfox/Books/Companion/>

- Gooskens, Charlotte i Vincent J. van Heuven (2017). Measuring cross-linguistic intelligibility in the Germanic, Romance and Slavic language groups. *Speech Communication* 89: 25–36, <https://doi.org/10.1016/j.specom.2017.02.008>
- Gooskens, Charlotte, Vincent J. van Heuven, Jelena Golubović, Anja Schüppert, Femke Swarte i Stefanie Voigt (2018). Mutual intelligibility between closely related languages in Europe. *International Journal of Multilingualism* 15(2): 169–193, <https://doi.org/10.1080/14790718.2017.1350185>
- Gooskens, Charlotte i Vincent J. van Heuven (2021). Mutual intelligibility. Zamperi, Marcos i Preslav Nakov ur. *Similar languages, varieties, and dialects: A computational perspective*. Cambridge University Press, 51–95.
- Hale, John (2001). A Probabilistic Earley Parser as a Psycholinguistic Model. *Second meeting of the north American chapter of the association for computational linguistics*, <https://aclanthology.org/N01-1021.pdf>
- Kamide, Yuki, Gerry Altmann i Sarah Haywood (2003). The time-course of prediction in incremental sentence processing: Evidence from anticipatory eye movements. *Journal of Memory and Language* 49(1): 133–156, [https://doi.org/10.1016/S0749-596X\(03\)00023-8](https://doi.org/10.1016/S0749-596X(03)00023-8)
- Beijering, Karin, Charlotte Gooskens i Wilbert Heeringa (2008). Predicting intelligibility and perceived linguistic distance by means of the Levenshtein algorithm. *Linguistics in the Netherlands* 25(1), 13–24. <http://www.wjheeringa.nl/papers/lin08.pdf>
- Kudera, Jacek, Irina Stenger, Philip Georgis, Bernd Möbius, Tania Avgustinova i Dietrich Klakow (2023). Cross-linguistic intelligibility of idiomatic phrases in Polish–Russian translation tasks. Colson, Jean–Pierre Colson ur. *Phraseology, constructions and translation: Corpus-based, computational and cultural aspects*, Presses universitaires de Louvain, 237–249. <https://pul.uclouvain.be/html/WYSIWYGfiles/files/103178-PUL-Deprez-Phrasology-C1-INT-C4.pdf>
- Kudera, Jacek (2022a). Slavic Receptive Multilingualism: Intercomprehension of Speech, universaar, <https://dx.doi.org/10.22028/D291-36578>
- Kudera, Jacek, Irina Stenger, Bernd Möbius, Tania Avgustinova, Dietrich Klakow (2022b). Phonetic Cues in Auditory Identification of Bulgarian, Czech, Polish, and Russian Language of Origin. *Language and Speech* 66(3), 606–624. <https://doi.org/10.1177/00238309221119098>
- Kudera, Jacek, Philip Georgis, Bernd Möbius, Tania Avgustinova, Dietrich Klakow (2021). Phonetic distance and surprisal in multilingual priming: Evidence from Slavic, *Interspeech 2021*: 3944–3948, <https://dx.doi.org/10.21437/Interspeech.2021-1003>
- Levenshtein, Vladimir (1966). Binary Codes Capable of Correcting Deletions, Insertions and Reversals. *Soviet Physics–Doklady* 10(8): 707–710
- Long, Jacob (2020). jtools: Analysis and Presentation of Social Scientific Data. R package version 2.1.0, <https://cran.r-project.org/package=jtools>
- Lüdecke, Daniel (2021). sjPlot: Data Visualization for Statistics in Social Science. R package version 2.8.9, <https://CRAN.R-project.org/package=sjPlot>

- Makowski, Dominique, Mattan Ben-Shachar, Indrajeet Patil i Daniel Lüdecke (2020). Automated Results Reporting as a Practical Tool to Improve Reproducibility and Methodological Best Practices Adoption. CRAN. <https://github.com/easystats/report>
- Mangiafico, Salvatore (2022). rcompanion: Functions to Support Extension Education Program Evaluation. R package version 2.4.13, <https://CRAN.R-project.org/package=rcompanion>
- Mosbach, Marius, Irina Stenger, Tania Avgustinova, Bernd Möbius i Dietrich Klakow (2021). incom.py 2.0 – Calculating Linguistic Distances and Asymmetries in Auditory Perception of Closely Related Languages. *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2021)*. 968–977. <https://aclanthology.org/2021.ranlp-1.110>
- Papoutsaki, Alexandra, Patsorn Sangkloy, James Laskey, Nediya Daskalova, Jeff Huang i James Hays (2016). Webgazer: Scalable Webcam Eye Tracking Using User Interactions. *Proceedings of the 25th International Joint Conference on Artificial Intelligence (IJCAI)*: 3839–3845. <https://cs.brown.edu/people/apapouts/papers/ijcai2016webgazer.pdf>
- Patil, Indrajeet (2021). Visualizations with statistical details: The ‘ggstatsplot’ approach. *Journal of Open Source Software* 6(61): 3167, <https://doi.org/10.21105/joss.03167>
- Peterson, Brian i Peter Carl (2020). PerformanceAnalytics: Econometric Tools for Performance and Risk Analysis. R package version 2.0.4. <https://CRAN.R-project.org/package=PerformanceAnalytics>
- R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>
- Revelle, William (2021). psych: Procedures for Personality, and Psychological Research, <https://cran.r-project.org/web/packages/psych/index.html>
- Sekicki, Mirjana i Maria Staudte (2018). Eye’ll help you out! how the gaze cue reduces the cognitive load required for reference processing. *Cognitive Science* 42(8): 2418–2458, <https://doi.org/10.1111/cogs.12682>
- Shannon, Claude (1948) A mathematical theory of communication. *The Bell System Technical Journal* 27(3): 379–423, <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Shannon, Claude i Warren Weaver (1949). A mathematical theory of communication. Urbana, University of Illinois Press, <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Stenger, Irina, Philip Georgis, Tania Avgustinova, Bernd Möbius i Dietrich Klakow (2022). Modeling the Impact of Syntactic Distance and Surprisal on Cross-Slavic Text Comprehension. In *Proceedings of the Thirteenth Language Resources and Evaluation Conference*. 7368–7376, Marseille, France. <https://aclanthology.org/2022.lrec-1.802>
- Tanenhaus, Michael, Michael Spivey-Knowlton, Kathleen Eberhard i Julie Sedivy (1995). Integration of Visual and Linguistic Information in Spoken Language Comprehension. *Science* 268(5217): 1632–1634, <https://doi.org/10.1126/science.7777863>
- Weber, Andrea i Anne Cutler (2004). Lexical competition in non-native spoken-word recognition. *Journal of Memory and Language* 50(1): 1–25, [https://doi.org/10.1016/S0749-596X\(03\)00105-0](https://doi.org/10.1016/S0749-596X(03)00105-0)

Wegener, Daune i Leandre Fabrigar (2000). Analysis and design for nonexperimental data: Addressing causal and noncausal hypothesis. Reis, Harry i Charles Judd, ur. *Handbook of Research Methods in Social and Personality Psychology*. Cambridge University Press, 412–450

How native speakers of Croatian understand other Slavic languages? Visual World Paradigm eye-tracking experiment

Speakers of closely related languages have a clear privilege when communicating with one another over speakers of typologically and genetically distant languages. They can use their L1s and conduct a relatively fluent conversation. Such a multilingual interaction is referred to as ‘intercomprehension’. The Slavic language family is a good example for testing intercomprehension due to extensive language contact and well documented historical development of each member of the language family. In this paper, we present an experiment in the Visual World Paradigm (VWP) to shed light on the factors facilitating and impeding mutual intelligibility. In a multilingual communication, speech comprehension depends on a degree of similarity between the languages and contextual (un)expectedness of elements coming from a closely related language. To quantify the first factor, we analyze the surface phonetic resemblance between the equivalents of cognate predicates across the Slavic languages; To address the question of stimulus (un) expectedness, we adopt a methodology of information theory. In this study, native speakers of Croatian are exposed to Bulgarian, Czech, Polish, and Russian sentences. Their task is to listen to foreign audio samples and watch the pictures referring to simple SVO-type sentences. We hypothesize that gaze anticipation effect measured on a visual field presenting a direct object is driven by the information theoretic notion of surprisal and phonetic similarity between the predicates in Croatian and a language of exposure. A strong intercomprehension effect was observed for Croatian native speakers listening to Polish sentences. The results of the eye-tracking experiment shed light on visually enhanced processing of closely related languages. The outcomes of this study contribute to the debate about the factors moderating mutual intelligibility among Slavic speakers.

Ključne riječi: pasivna višejezičnost, hrvatski jezik, slavenski jezici, metoda praćenja pokreta očiju, razumijevanje rečenice, auditivni modalitet

Keywords: receptive multilingualism, Croatian language, Slavic languages, visual world eye-tracking paradigm, sentence comprehension, auditory modality