



## **Središnja medicinska knjižnica**

**Brangan, Sanja (2011) *Razvoj formula čitkosti za zdravstvenu komunikaciju na hrvatskom jeziku [Developing readability formulas for healthcare communication in Croatian language]. Doktorska disertacija, Sveučilište u Zagrebu.***

<http://medlib.mef.hr/1414>

University of Zagreb Medical School Repository

<http://medlib.mef.hr/>

**SVEUČILIŠTE U ZAGREBU  
MEDICINSKI FAKULTET**

**Sanja Brangan**

**Razvoj formula čitkosti  
za zdravstvenu komunikaciju na hrvatskom jeziku**

**DISERTACIJA**

**Zagreb, 2011.**

**Rad je izrađen na Školi narodnog zdravlja “Andrija Štampar”, Medicinskog fakulteta, Sveučilišta u Zagrebu.**

**Mentor rada: doc. dr. sc. Gorka Vuletić Mavrinc**

**Redni broj rada:**

# SADRŽAJ

1. UVOD .....	1
1.1.    Zdravstvena komunikacija .....	2
1.2.    Zdravstvena pismenost .....	16
1.2.1.  Testiranje zdravstvene pismenosti .....	21
1.3.    Čitanje i čitalačka sposobnost .....	23
1.4.    Čitkost i formule čitkosti .....	26
1.4.1.  Polazište i razvoj formula čitkosti .....	27
1.4.2.  Formule čitkosti za engleski jezik .....	30
1.4.3.  Formule čitkosti za neenglesko govorno područje .....	44
1.4.4.  Kritike i ograničenja formula čitkosti .....	50
2. HIPOTEZE I CILJEVI ISTRAŽIVANJA .....	52
3. MATERIJALI I METODE .....	53
4. REZULTATI .....	57
5. RASPRAVA .....	84
6. ZAKLJUČCI .....	100
7. SAŽETAK .....	101
8. SUMMARY .....	102
9. LITERATURA .....	103
10. ŽIVOTOPIS .....	113
11. PRILOZI	
11.1.    Prilog 1	
11.2.    Prilog 2	

## 1. UVOD

Disertacija pod gore navedenim naslovom izrađena je u okviru znanstvenog projekta „Razvoj modela i instrumenta za ocjenu zdravstvene pismenosti u Hrvatskoj“, kojeg financira Ministarstvo znanosti, obrazovanja i sporta Republike Hrvatske pod brojem 108-1080317-0313. Svrha cjelokupnog projekta je razviti model i instrument za ocjenu zdravstvene pismenosti koji će biti prilagođen zdravstvenom sustavu u Hrvatskoj, kao i jeziku hrvatske populacije. Rezultati projekta bi trebali omogućiti uvođenje zdravstvene pismenosti kao one determinante zdravlja za koju u Hrvatskoj još uvijek ne postoje niti podaci, niti instrument odnosno model kojim bi se ti podaci mogli prikupljati, a važnost i hitnost razvoja takvog instrumenta potvrđuje činjenica da se u 2011. godini očekuju prvi podaci o zdravstvenoj pismenosti u državama Europske unije [1]. Pretpostavka je da će rezultati projekta omogućiti bolju identifikaciju onih rizičnih skupina u zdravstvenom sustavu kojima je pristupačnost zdravstvene zaštite smanjena zbog ove determinante zdravlja, što će za posljedicu imati veću orijentiranost ka pacijentu te povećanje kvalitete zdravstvene zaštite uz smanjenje troškova.

Svrha ove disertacije je da se za potrebe gore navedenog projekta razvije model za kvantitativnu ocjenu kompleksnosti pisanih materijala, što je polazište za izradu instrumenta kojim će biti moguće procijeniti zdravstvenu pismenost, a takav model ne postoji za hrvatski jezik. Pretpostavka je da će primjena rezultata ove disertacije pridonijeti smanjivanju zdravstvenih nejednakosti u pristupačnosti zdravstvene zaštite s

komunikacijskog aspekta, ali da će istovremeno postaviti temelje za razvoj sličnih modela u drugim zemljama neengleskog govornog područja.

Disertacija obuhvaća pregled relevantne stručne literature iz područja koja su nužna za opis važnosti i upotrebe formula čitkosti u području zdravstva, a to su svakako: zdravstvena komunikacija, zdravstvena pismenost, testovi za ocjenu funkcionalne zdravstvene pismenosti, čitanje i čitalačka sposobnost te formule čitkosti kroz povijesni pregled, pregled po vrstama i upotrebi za različite jezike.

Za potrebe ovog istraživanja, a sukladno empirijskim studijama čitkosti za druge jezike, analiza tekstova obuhvaća kvantitativnu kontrastivnu analizu prijevodnih tekstova na engleskom i hrvatskom jeziku, različite kompleksnosti, a koji su javno dostupni te nije potreban pismeni pristanak za njihovo korištenje.

## **1.1. Zdravstvena komunikacija**

Za potrebe ovoga rada pojam “zdravstvena komunikacija” koristit će se u užem smislu komunikacije između liječnika te ostalih zdravstvenih djelatnika i pacijenata, korisnika zdravstvene zaštite, u svrhu promicanja zdravlja i sprečavanja bolesti. To obuhvaća komunikaciju u onim osjetljivim područjima za koja je uspješna komunikacija od presudne važnosti, kao naprimjer kod informiranog pristanka, kod prikupljanja podataka od pacijenata, kod znanstvenih istraživanja koja uključuju pacijente, komunikaciju s pojedinim skupinama pacijenata ili s općom populacijom i slično.

Uspješna komunikacija ima glavnu ulogu u odnosu liječnik-pacijent budući da istraživanja pokazuju da ona pozitivno utječe na zadovoljstvo i suradljivost pacijenata te na ishode liječenja, a ujedno smanjuje troškove zdravstvene zaštite i time povećava ukupnu kvalitetu zdravstvene zaštite [2-5]. To naročito dolazi do izražaja kod informiranog pristanka, gdje se od pacijenata očekuje da sudjeluju u procesu odlučivanja time što odvaguju koristi i rizike preporučenih vrsta liječenja [6]. Kako bi bili kompetentni sudionici u odlučivanju, pacijenti moraju razumjeti što same preporuke znače i prodiskutirati ih s liječnicima na adekvatan način. Tek tada mogu aktivno sudjelovati u toj komunikacijskoj interakciji, što je pretpostavka za zajedničko donošenje odluka [7]. Informirani pristanak, ili točnije pristanak informiranog, obaviještenog pacijenta, znači da pacijent razumije svoju situaciju, zna posljedice različitih odluka od kojih jednu treba donijeti i da je osposobljen donijeti odluku bez straha i bez pritiska koji bi mogli smanjiti njegovu sposobnost donošenja odluke [8]. Pacijenti imaju pravo odlučivati i dobiti sve dostupne relevantne informacije kako bi mogli odlučivati. Međutim, dobivanje suglasnosti od pacijenta nije jednokratni čin, to je proces koji se treba uspostaviti kroz cijeli odnos između liječnika i pacijenta [9]. U svakom slučaju, važnost informiranog pristanka leži u činjenici da on pokazuje kako je došlo do nekog razgovora između liječnika i pacijenta, odnosno ispitanika u kliničkim istraživanjima, da se barem vidi pokušaj da se prava pacijenata štite na ovaj način. Osim toga, ne samo da je informirani pristanak od iznimne važnosti za etičko ravnanje bilo koje medicinske intervencije, već on pridonosi jačanju odnosa liječnik-pacijent te povećava vjerojatnost uspjeha dijagnostičkih, terapijskih i istraživačkih intervencija [10].

U kliničkoj praksi liječnik se svakodnevno suočava s nizom problema vezanih za informirani pristanak. Jedan od njih je količina informacija koja je nužna za informirani pristanak. Da li je uopće moguće dati potpunu i cjelovitu informaciju? Moraju se odabrati oni podaci koji su relevantni za pacijenta i koji će ga osposobiti za donošenje kompetentne odluke [11]. U protivnom, premalo ili previše informacija može dovesti do kontraproduktivnog učinka: pacijent će se žaliti da mu nije sve rečeno ili će se žaliti da je pretrpan gomilom detalja od kojih ne može razlučiti ono bitno. Osim fiziologije i metodologije koju će primijeniti, liječnik treba objasniti i etiologiju i tijek bolesti, dobre i loše strane različitih mogućnosti liječenja, relativne rizike, očekivano trajanje oporavka te kako se ono može poboljšati, koja je podrška dostupna, dugoročne posljedice bolesti uz daljnje liječenje, nužan oprez i promjene u načinu života koji može poboljšati tjelesno i duševno zdravlje [12].

Novija istraživanja komunikacijskog aspekta odnosa liječnik-pacijent potvrđuju važnost informacija i jezika kojim se služi liječnik. Cassell uočava kako korektna informacija može biti važno terapijsko sredstvo, jer smanjuje nesigurnost, osigurava osnovu za akciju i jača odnos između liječnika i pacijenta [13]. No, brojna istraživanja također pokazuju da pacijenti vrlo malo pamte odnosno razumiju od onoga što im je kroz proces informiranja dano na znanje [14,15]. Istraživanje Lloyda i sur. [16] o informiranju pacijenata pokazuje da je samo jedan pacijent od ukupno 71 zapamtio informacije o opisanim rizicima. Gattelarijeva i sur. [17] dobivaju slične rezultate s pacijentima s karcinomom: manje od 20% ih je znalo kolika je vjerojatnost da im liječenje izliječi bolest.



Komunikacija je, općenito gledano s aspekta teorije komunikacije, “prenošenje obavijesti kojim se želi postići neki učinak” [18]. Postoje različiti modeli komunikacije. Stariji modeli komunikacije smatrali su informaciju nekom vrstom predmeta koji kroz kanal prelazi od jedne osobe drugoj, npr. interpersonalnim kanalom ili masovnim medijem. Unutar takvog modela, ako nema smetnji i ako pošiljatelj posjeduje dovoljno komunikacijske vještine, primatelj informacije razumjet će značenje poruka što ih šalje izvor [19]. Takav je i model komunikacije zasnovan na matematičkoj teoriji autora Claudea Shannona i Warrena Weavera, kojeg objašnjavaju u knjizi “Mathematical Theory of Communication” iz 1949. godine [20]. James Lutkin prikazuje komunikaciju također matematički, tj. dajući formulu komunikacijskog procesa. On smatra da, kada se reduciraju tehnički elementi i nevažne varijable, odnosno kada se jezik standardizira i količina podataka ograniči, najvažniji dio komunikacije ostaje govornikova želja za komuniciranjem [21].

Noviji modeli komunikacije komunikatore vide drugačije, tj. kao da se nalaze u “aktivnosti predviđanja”, ili da su “proizvođači značenja”. Ljudi selekcioniraju informacije na osnovi svojih potreba, želja i mogućnosti. Značenja koja će iz njih izvesti pod utjecajem su povezivanja ili integracije s prethodnim iskustvom, kao i naših potreba i očekivanja [19]. To znači da se značenje neke poruke formulira tek u svijesti njenog primatelja, jer ovisi o sociološkim, psihološkim, kulturnim, formalno-jezičnim i drugim obilježjima ili ograničenjima procesa komuniciranja. To ujedno znači da odašiljatelj poruke nikada ne može biti potpuno siguran da će primatelj tu poruku ispravno i potpuno razumjeti [22].

Prema teoriji informacija, teoriji koja kvantificira informaciju, određujući njezinu vrijednost na osnovi doprinosa poznavanju situacije, poruke moraju smanjivati neizvjesnost da bismo ih mogli smatrati informacijama [19]. Za potrebe komunikacije, svaki jezik od mnogih mogućih alternativa uvijek koristi samo ograničen broj. Drugim riječima, opseg informativnosti datog elementa ovisi o stupnju do kojega se on može predvidjeti na osnovu konteksta [20]. Predvidljivost nekog elementa je vrlo važna za prepoznavanje govora. Razumljivost može biti znatna čak i kada nedostaju važni elementi. Kontekst u kojem neki iskaz nastaje, vanjske okolnosti, kao i sve što je prije njega rečeno, u velikoj mjeri ograničavaju stvarne mogućnosti izbora. Tako kontekst kao oblik redundantnosti, olakšava komunikaciju [20]. Ljudi često upotrebljavaju riječi kao da one za svakoga imaju ista značenja, a u stvarnosti možemo smatrati velikom srećom kad osoba s kojom razgovaramo razumije velik dio naših značenja na jednak način kao što to mi činimo [19]. Jedna od glavnih zapreka razmjeni informacija sastoji se u razlikama značenja što ih ljudi pridaju istim riječima ili djelima. To je jedan od osnovnih razloga zbog kojih ljudi nailaze na teškoće u komuniciranju. Ljudi komuniciraju poruke, a one su potencijalno smislene i informativne, odnosno mogu dobiti značenje. To je značenje pod utjecajem denotacija i konotacija riječi. Denotativno značenje je deskriptivno značenje koje je zajedničko većini ljudi neke kulturalne sredine. Konotativno značenje je osobno značenje koje nije lako otkriti i koje ne mora biti zajedničko većem broju ljudi. Budući da su riječi nabijene konotacijama, njihove interpretacije su višestruke [19].

Oblikovanje ili konstruiranje poruka nije moguće bez odgovarajućih znanja. U području medicine i zdravstva jedna od mogućnosti usvajanja znanja je zdravstvena edukacija od temeljnih do viših razina, ali laik nikada ne može doseći razinu stručnosti a da i sam ne

postane stručnjak. Međutim, nedostatak takvog pristupa je činjenica da se znanje neprestano, a u zadnje vrijeme strelovito širi, gdje medicina nikako nije izuzetak ako se uzmu u obzir nova saznanja, razvitak novih tehnologija i reevaluacija postojećeg znanja u obliku znanstveno utemeljene medicinske prakse. Još uvijek postoje velike praznine u tom znanju pa podatak da je uspješnost liječenja nepoznata u čak 90% medicinskih problema u rutinskoj praksi [4] može djelovati zastrašujuće za pacijenta. Stoga postoji potreba da se poruke koje nose informacije ipak prilagođavaju na način da se “prevode” sa stručnog na laički jezik, što se može nazvati “intralingvalno prevođenje” [23]. Za uspješno oblikovanje i razmjenu značenja prijeko je potrebno i poznavanje osobe ili osoba kojima želimo poslati poruke. Istraživači komunikacije još su od Aristotela bili svjesni potrebe prilagođavanja poruke slušateljstvu pa se uz karakteristike teksta mora voditi računa i o karakteristikama sugovornika [24]. Težak [25] vrlo kratko i jasno objašnjava svrhu komunikacije: “Pisati i govoriti znači uvjeriti. Uvjeriti može onaj tko zna koga i zašto uvjerava te umije pronaći najsvrsishodniji izraz za to uvjeravanje. Kulturno govoriti ili pisati znači funkcionalno iskoristavati riječ, u skladu s predmetom, svrhom i sudionikom komunikacije” [25].

Komunikacija je vrlo važna u fazi postavljanja dijagnoze. Liječnik mora postaviti vrlo specifična pitanja kako bi pomogao pacijentu da mu pruži potrebne informacije koje će moći prevesti u medicinske podatke i na osnovu njih postaviti dijagnozu. Taj proces liječnik mora obaviti bez obzira na to koliko zbunjujuće ili nepotpune bile informacije koje mu pacijent daje [26]. Važnost komunikacije za postavljanje dijagnoze posebno je naglašena u psihoterapiji, o čemu svjedoči klasični rad Radliča i Hollingsheada, pokazujući da različit jezik između liječnika i pacijenta može biti razlog neuspješnosti liječenja [27].

Novije izdanje rječnika medicinske etike ("The New Dictionary of Medical Ethics") svoje opise pojedinih pojmova prilagođava aktualnoj filozofiji odnosa liječnik-pacijent. Komunikacija se sagledava kroz sljedeći opis: "Neetično je očekivati od liječnika i medicinskih sestara da učinkovito komuniciraju, a da ih njihovo obrazovanje ne osposobi u neophodnim komunikacijskim vještinama i strategijama, da im ne da samopouzdanje kako da ih koriste, te ako ih ne uvjeri u njihovu vrijednost kako za pacijente tako i za njih same." [28].

Stručnu komunikaciju karakterizira poseban stil. Stručna komunikacija ima svoju dugu povijest, ali je bila jezično zanemarivana pa je tek šezdesetih i sedamdesetih godina 20. stoljeća dobila svoju lingvističku afirmaciju u okviru sociolingvistike. Sa sociolingvističkog stajališta, u središtu pozornosti stručne komunikacije nalazi se stručnjak u određenom znanstvenom području ili disciplini, a njegova jezična kompetencija može se smatrati pomoćnim sredstvom u službi stručnih znanja. Kako se kod jezika struke radi o odmaku od općeg jezika, kada u stručnoj komunikaciji sudjeluju i "obični" korisnici stručnih znanja, komunikacijska barijera može izazvati osjećaj bespomoćnosti do odustajanja od namjere [29].

Uspješnost interakcije između liječnika i pacijenta ovisi o njihovoj sposobnosti da razumiju jedni druge. Brojna istraživanja pokazuju da liječnikov neuspjeli pokušaj da pacijentu objasni zdravstveno stanje u kome se našao na jednostavan način predstavlja vrlo velik problem odnosa liječnik-pacijent. S druge strane, mnogi će liječnici reći da je razlog tog neuspjeha što ih pacijenti ne razumiju ili da bi informacije mogle negativno utjecati na pacijente, a analize pokazuju da liječnici često upravo izbjegavaju komunikaciju ili bježe u profesionalni žargon [30]. Budući da je iznimno velik postotak onih pacijenata koji ne razumiju ili ne pamte ono što im liječnik govori o dijagnozi i liječenju, kao razlog se često navodi da je jezik koji liječnici koriste nejasan, da koriste žargon te da se ni u značenju nekih općih termina liječnik i pacijent ne slažu uvijek [31]. U tom se kontekstu i profesionalni jezik tj. žargon javlja ne samo

kao element profesionalne kulture, već i kao oblik otpora deprofesionalizaciji struke. Proučavanja funkcija profesionalnog jezika pokazuju da su one višestruke [32,33]: profesionalni jezik je kondenziran i time štedi vrijeme u profesionalnoj komunikaciji; olakšava međusobno prepoznavanje članova profesije; te ima funkciju da javnost drži na distanci, jer ona “ne razumije o čemu se radi”. Profesionalni jezik se tako koristi za stvaranje distance između liječnika i pacijenta, ali i za održavanje informacijske kontrole [32,33]. Međutim, budući da su liječnici “bilingvalni”, tj. govore i svakodnevni i stručni jezik, dok pacijenti govore samo svakodnevni jezik, očekuje se od liječnika da svoj jezik prilagode u kontaktu s pacijentima. Nažalost, da se to ne događa uspješno, svjedoče brojni primjeri nesporazuma u komunikaciji, koji znatno utječu na zadovoljstvo pacijenata, ali ponekad i na ishod liječenja [34].

Zdravstvene informacije za pacijente stoga treba vrlo pažljivo planirati i sastavljati vodeći računa o tome kome su točno namijenjene, u koju svrhu i s kojim ciljevima. Nakon što se odredi koja je ciljana populacija te utvrde njene sociodemografske karakteristike, potrebno je odabrati komunikacijski kanal, a zatim i opseg i sadržaj poruke. Nakon dovršenog prilagođavanja informacija ciljanoj populaciji, još ih je potrebno testirati na konkretnoj ciljanoj populaciji i po potrebi revidirati [35].

Za sastavljanje pisanih materijala za pacijente postoje preporuke različitih udruženja, ustanova, ali i pojedinih autora. Općenito govoreći, poruka se mora prilagoditi svakom pojedinom pacijentu vodeći računa o njegovim osobinama, kao npr. dob, spol, obrazovanje, zanimanje, ali i o nekim općim karakteristikama jezika koje se pokazuju uspješnima u komunikaciji. Općeniti savjeti uključuju sljedeće: “Ako je zbrka u glavi, uzalud sva pravopisna pravila i bogatstvo rječnika.” [25]; “Pravilno je ono što ljudi mogu najbolje i najbrže shvatiti, a što onaj koji govori najlakše može izraziti.” [25]; “Ono što je najlakše reći, najlakše je i razumjeti.” [25]. Da bi se do takvog rezultata došlo, mora se proći faza planiranja, gdje se određuje što sve čitatelj mora saznati da bi

shvatio poruku, a vodi se računa o izboru riječi ovisno o tome kakvog će učinka imati pojedina riječ na čitatelja [36].

U svim oblicima komunikacije kada se profesionalci obraćaju laicima i široj javnosti moraju u prvom redu voditi računa o osobinama skupine odnosno pojedinaca kojima se obraćaju. Upravo će komunikacijom uspjeti pomiriti međusobne razlike u mišljenju svojim nastojanjima da dođu do zajedničkog cilja [37]. Budući da ipak primarno govore zajedničkim jezikom, a ona dopunska terminologija koja je toliko prikladna u komunikaciji s kolegama može i mora biti izostavljena odnosno prilagođena novim slušateljima, na profesionalcima je da pronađu način kako se jezično približiti i prilagoditi u novoj situaciji i ostati razumljivi i drugima [36].

Davisova [37] predlaže nekoliko strategija kako se profesionalci, prvenstveno znanstvenici, trebaju prilagođavati svojoj laičkoj publici. Na prvom mjestu je identifikacija publike, gdje su najvažniji čimbenici za razumijevanje publike njihova dob i obrazovna razina. U svakom slučaju, kakva god prilagodba bila nužna, ne postoji nikakav opravdan razlog zašto komunikacija ne bi mogla biti uspješna. Bitno je samo da se nove informacije nadovežu na ono što je već poznato određenoj publici, tj. da se gradi na njenom iskustvu [37]. Drugi važan korak je jasno utvrditi cilj i svrhu komunikacije. Bitno je razlučiti što će se reći, s kojim ciljem i do koje širine, jer u ograničenom vremenu usmene komunikacije ili ograničenom prostoru pisanog teksta odmah mora biti vidljivo što je bitno, a što su dodatne obavijesti. Zanimanje publike za izlaganje koje se nudi ponekad je neobično važno kako za održavanje pažnje, tako i za razumijevanje rečenog odnosno napisanog. Isto tako, iskrenost izlaganja, što će ponekad značiti i priznanje neznanja, samo će pojačati povjerenje u izlagatelja [37]. Od

preporučenih tehnika, Davisova spominje jednostavnost, točnost, potpunost i jasnoću. Jednostavnost će se postići konverzacijskim tonom, direktnim oslovljavanjem, ponavljanjem glavnih ideja radi naglašavanja, govorom u prvom i drugom licu te upotrebom aktiva umjesto pasiva. Treba paziti na ton izražavanja i pomno birati riječi; prihvatljivi su samo oni sinonimi koji su razumljivi laicima i široj javnosti. Složenost izražavanja i nepotpune izjave treba izbjegavati, kao i pogrešno napisane riječi ili gramatičke pogreške, koje će ne samo otežati razumijevanje, već i frustrirati slušatelja odnosno čitatelja. Sve rečeno ili napisano mora imati logičan slijed, ali ti logični prijelazi moraju biti očiti prvenstveno namijenjenoj publici, a ne samo stručnoj osobi. Dakle, i očekivanja publike moraju se uzeti u obzir kod koncipiranja poruka. Jasnoća izražavanja bit će postignuta samo ako neku riječ ili ideju kakvom ju je zamislio pošiljatelj poruke u istom značenju shvati i primatelj poruke. Zbog svega ovoga se uvelike preporučuje da svaki tekst namijenjen laicima prođe reviziju kako bi se izbjegli nesporazumi bilo koje vrste [37].

Jedna druga inicijativa, koja vrlo detaljno proučava i razrađuje sve vrste pisanih informacija za pacijente, potekla je iz farmaceutske tvrtke Pfizer pod nazivom "Clear Health Communication Initiative" [38], nakon što je na državnoj razini 1998. godine usvojen zahtjev da se sve državne agencije SAD-a obvežu u svojim materijalima koristiti jednostavan jezik [39]. Razlog pokretanja Pfizerove inicijative je činjenica da postoji potreba za jasnim i jednostavnim zdravstvenim informacijama bez obzira na obrazovni stupanj čitatelja, a znanstvene informacije su po svojoj prirodi preteške za razumijevanje te ih treba pojednostavniti odnosno prilagoditi čitateljstvu. Rezultat ove inicijative su smjernice kako sastaviti zdravstvene informacije koje će biti pristupačne širokoj publici, a namijenjene su onima koji sastavljaju tekst, ali i dizajnerima vizualnih

ilustracija. Naglasak kod izrade pisanih materijala za pacijente je da svi materijali moraju biti prilagođeni čitalačkim sposobnostima te kulturi i osobnosti pacijenata, koristeći jednostavan jezik, jednostavan vizualni izgled i jednostavne ilustracije koje će pojasniti tekstualni dio, a temeljit će se manje na medicinskim činjenicama, a više na pacijentovu viđenju zdravstvenog stanja i na željenim oblicima ponašanja. To znači da, budući da je glavni cilj bilo koje zdravstvene informacije za pacijente uključiti same pacijente da aktivno sudjeluju u zaštiti svog zdravlja, potrebna je takva informacija koja će biti korisna, što za potrebe američkog sustava znači napisana na stupnju čitanja 6. razreda kako bi je razumjelo barem 75-80% ljudi u SAD-u, odnosno općenito rečeno, informacija jednostavna za čitanje, ali i razumijevanje. Kako to postići, objašnjeno je vrlo detaljnim i konkretnim smjernicama [38]. Pfizerove smjernice za izradu pisanih materijala za pacijente, koji će biti privlačni i učinkovito prenositi važne zdravstvene informacije, obuhvaćaju pet glavnih principa: 1) objasniti svrhu i ograničiti sadržaj; 2) uključiti čitatelja; 3) učiniti jednostavnim za čitanje; 4) učiniti da izgleda jednostavno; 5) izabrati vizualne ilustracije koje će pojasniti i motivirati [38]. Preporuke za pisanje edukacijskih materijala za pacijente mogu se pormatrati s aspekta: 1) organizacije (jasno naglasiti korake i dati ono bitno, služeći se naslovima i sažecima), 2) stila (aktivni glagoli i konverzacijski ton te kratke rečenice uz izbjegavanje žargona, kompleksnost primjerena publici), 3) izgleda (nenatrpne stranice pune bijelog prostora na papiru; veličina slova 12 do 14 čitljivog oblika slova, najviše tri različita oblika slova po stranici; naglašeni tekst masnim slovima ili uokviren u kućicama), 4) ilustracije (jednostavne slike koje privlače pažnju i naglašavaju tekst, a primjerene su publici), 5) dojma (odgovarajući za različite kulture, dob, poticanje interakcije, korištenje dijaloga, priča, svjedočanstava i sl.).



Osim priznatih autora o učinkovitom stilu pisanja [14,37,40], farmaceutskih tvrtki koje daju svoje smjernice o informacijama za pacijente [38], državnih ustanova [35], brojne druge organizacije širom svijeta pokušavaju pomoći ukazujući na slabu razumljivost pisanih materijala namijenjenih laicima i nudeći svoje preporuke [41-43]. Budući da se preporuke vrlo često ponavljaju i preklapaju, u sljedećem tekstu je dan sažeti pregled osnovnih preporuka prema gore navedenim izvorima.

Kod pisanja informacija za pacijente mora se voditi računa o publici, što znači i o veličini vokabulara, koji bi trebao biti ograničeniji, koristiti samo neka značenja određenih riječi, a apstraktne imenice zamijeniti glagolima i pridjevima. Gramatika treba biti pojednostavljena, što znači i izbjegavati pasiv, koji je težak i kompliciran. Treba slijediti logičku jednostavnost, identificirati osnovne ideje i njihove cjeline, zatim složiti cjeline u logičan slijed, prevesti cjeline u jednostavan jezik te prestrukturirati i spajati zadržavajući izvorne vezne elemente. Pritom treba koristiti tiskana pomagala (priručnike, leksikone, rječnike) te kompjutorske programe radi testiranja čitkosti, provjere gramatike i odabira standardnih sinonima. Ogromna količina vrlo preciznih detaljnih preporuka može se sažeti grupiranjem na razini teksta i na razini vizualnog. Na razini teksta savjetuje se početi s najvažnijim i poznatim informacijama, jer poznati kontekst olakšava pamćenje i razumijevanje; zatim jasno reći što pacijent mora znati i učiniti (npr. kod lijekova: koliko tableta, koliko često, kada i s čime); zatim sažeti i ponoviti ključne poruke (a kod dužih pisanih materijala, brošura itd. dati sažetak na kraju svakog poglavlja); a detalje, nužnu statistiku ili detaljniji postupak dati u posebnom odjeljku ili na posebnoj stranici, te se pritom stalno direktno obraćati čitatelju povezujući informacije s njegovim okruženjem, stavljajući ih u njemu poznati kontekst i poticati ga na aktivnu ulogu. Korištenje primjera i dodatnih objašnjenja pojednostavljuje

poruku, čini je jasnijom i povećava razumijevanje, jer onaj koji nešto govori vrlo dobro zna na što misli, ali njegov sugovornik ne mora to nužno odmah prepoznati. Treba izbjegavati određene riječi, kao npr. medicinske termine odnosno žargon, ali i latinske odnosno grčke prefikse, jer će čitatelji razumjeti ostatak riječi a prefiks zanemariti i tako pogodajući značenje riječi pogrešno shvatiti tu riječ, ali i cijelu poruku. Budući da na čitkost pisanih materijala prvenstveno utječe dužina rečenice i količina “teških” tj. višesložnih riječi, tekst će biti jednostavniji ako rečenica nema više od 15 riječi, ako se koriste jednostavne riječi s manjim brojem slogova odnosno učestalije riječi, ako se izbjegavaju složene riječi i bilo koji nepotreban tekst. Poželjan je konverzacijski stil, aktivan a ne pasivan vid glagola koji je sporiji i duži. Tekst treba logički strukturirati tako da svaki dio govori o samo jednoj ideji ili temi, što znači da se složeniji tekst treba razbiti u manje cjeline ponekad i s podnaslovima, a preporučuje se korištenje vizualnih sredstava za povezivanje, odvajanje, naglašavanje i ilustriranje. Pokazalo se da se ljudi teško snalaze kad neki popis sadrži više od sedam natuknica, jer tada neće upamtiti samo pet ili sedam, nego neće upamtiti nijednu.

Na razini vizualnog navodi se da vizualne ilustracije moraju služiti kao podrška tekstu, pojašnjavati ga, pojednostavljivati i nadopunjavati. Ilustracije su vrlo važne, jer one prve privlače pažnju čitatelja, nakon čega pogled odlazi na tekst ispod ilustracija, a tek zatim na ostali tekst. Zbog toga je kvaliteta ilustracije odnosno njena jasnoća i privlačnost presudna za odluku hoće li čitatelj uopće pročitati ostatak teksta. Osim toga, vizualne ilustracije povećavaju sposobnost čitatelja da upamti predočene informacije. Ilustracije ne smiju imati previše detalja, jer nepotrebno odvrćaju pažnju od bitnoga, a moraju biti prilagođene uzrastu pacijenta (npr. dječji ili djetinjasti crteži nisu primjereni odrasloj populaciji), ali i ozbiljnosti situacije (npr. karikature ili apstraktne vizualne

poruke samo zbunjuju i ometaju pacijente). Također, treba izbjegavati kopije ilustracija iz medicinskih udžbenika, jer nisu primjerene široj publici. Tekst ispod ilustracija objašnjava o čemu se na slici radi te pomaže čitatelju da zna na što posebno obratiti pažnju, naročito ako se radi o grafikonu, popisu i sl. Ako neku tablicu ili dnevnik treba popunjavati, preporučuje se dati primjer kako to treba ispuniti i što dalje s time napraviti. Vizualne ilustracije koje nisu relevantne za poruku samo odvlače pažnju i nepoželjne su. Zato vizualni putokazi pojačavaju jasnoću i olakšavaju pamćenje: preporučuje se upotreba naslova, podnaslova, numeriranja, svrstavanja u tablice, masnije otisnut tekst ili podvučen tekst, vrlo oprezna upotreba boja, itd., jer se na taj način naglašavaju neki dijelovi informacije (npr. uvećani tekst ili slika, strelice, itd.). Dobar kontrast papira i otisnutog teksta odnosno slike, kao i veća slova (preporučuje se barem veličina 12) olakšavaju čitanje, pa treba izbjegavati bilo kakva zamagljivanja teksta ili korištenje uzoraka podloge zbog kojih se slova dobro ne vide. Ono što izgleda jednostavno potiče ljude na čitanje, tj. izgleda privlačnije i zanimljivije. Puno bjeline tj. prostora oko teksta djeluje privlačnije za čitanje, kao i dvostruki prored, šire margine, više ilustracija nego teksta. Upotreba boja treba biti realistična, svrsishodna, može se koristiti za naglašavanje, a nipošto ne smije biti samo dekorativna.

Kao provjeru težine već sastavljenih informacija, preporučuje se korištenje neke od postojećih formula čitkosti. Ističe se testiranje gotovih materijala na pacijentima odnosno potencijalnim čitateljima kao najučinkovitiji način da se dobiju dodatne vrijedne informacije i mišljenje o tekstu i grafičkom oblikovanju. Neke preporuke nude i vrlo korisne gotove popise riječi koje treba izbjegavati odnosno riječi koje se preferiraju, ali većina tih preporuka odnosi se na engleski jezik pa se popisi riječi ne mogu direktno primijeniti na informacije na hrvatskom jeziku.

## **1.2. Zdravstvena pismenost**

Dosadašnje spoznaje u području zdravstvene komunikacije govore o iznimnoj važnosti zdravstvene pismenosti populacije, jer istraživanja u svijetu pokazuju da je pismenost najjači prediktor zdravstvenog stanja pojedinca, čak ispred dobi, obrazovanja, prihoda, zaposlenosti ili pripadnosti etničkim skupinama [44]. Nadalje, istraživanja pokazuju da je stupanj zdravstvene pismenosti direktno povezan s uspješnošću komunikacije, što uvelike utječe na suradljivost pacijenata, ishod liječenja, učestalost korištenja zdravstvene zaštite, troškove i ukupnu kvalitetu zdravstvene zaštite [2-5]. Tako se za pacijente s niskom razinom pismenosti troši više novca u zdravstvenom sustavu, oni duže ostaju u bolnici i češće odlaze liječniku [45-47], ali rjeđe koriste preventivne usluge [1,48]. Također, takvi pacijenti imaju lošije zdravstveno stanje i ishod njihova liječenja je lošiji [49,50], a ujedno su i nezadovoljniji zdravstvenom zaštitom [51]. S komunikacijskog i etičkog stajališta, adekvatna zdravstvena komunikacija, koja uzima u obzir stupanj pismenosti pojedinca, povećava pristupačnost zdravstvenoj zaštiti i jača aktivnu ulogu pacijenta u zdravstvenom sustavu, što je temelj kvalitetnog odnosa između liječnika i pacijenta, ali i zdravstvene politike kojoj je cilj povećanje sveukupne kvalitete zdravstvene zaštite te zaštite prava pacijenata.

Zdravstvena pismenost se definira prije svega kao “osobna, kognitivna i društvena umijeća koja određuju sposobnost pojedinaca da dođu do, razumiju i koriste informacije kako bi unaprijedili i održavali zdravlje” [52], a zadovoljavajući stupanj funkcionalne zdravstvene pismenosti nužan je da bi pacijenti mogli sudjelovati u ostvarenju svoje

zdravstvene zaštite. Važnost aktivnog sudjelovanja u donošenju odluka na temelju adekvatne informiranosti ogleda se u sljedećoj definiciji zdravstvene pismenosti: “stupanj do kojega su pojedinci sposobni doći do, obraditi i razumjeti osnovne zdravstvene informacije i usluge potrebne za donošenje odgovarajućih zdravstvenih odluka” [53]. U definiciji “splet vještina, uključujući i sposobnost obavljanja osnovnih zadataka čitanja i računanja, a koje su nužne za funkcioniranje u zdravstvenom okruženju” [54] zdravstvena pismenost se vrlo direktno veže uz pojam opće pismenosti s naglaskom na čitanje i računanje, ali se stavlja u zdravstveni kontekst. Novija definicija zdravstvene pismenosti nudi jedan prošireni model i naglasak stavlja na različitost dimenzija sposobnosti pojedinca, ali i širi kontekst svrhe tih sposobnosti, te glasi: “cijeli niz vještina i kompetencija koje ljudi razvijaju kako bi potražili, shvatili, ocijenili i koristili zdravstvene informacije i pojmove u svrhu donošenja informiranih odluka, smanjenja zdravstvenih rizika i veće kvalitete života” [55]. Na kraju, jedna definicija koja ne definira konkretne sposobnosti pojedinca, već naglašava suvremeni pristup odnosu liječnika i pacijenta u kome obje strane zajednički i odgovorno dogovaraju, odlučuju i djeluju: “zajednička odgovornost unutar koje pacijenti i zdravstveni radnici moraju komunicirati svatko na način da ga onaj drugi razumije” [56].

Funkcionalna zdravstvena pismenost može se definirati kao „dostatna osnovna umijeća čitanja i pisanja kada čovjek može djelotvorno funkcionirati u svakodnevnim situacijama“ [52], gdje se naglasak stavlja na ono što se pismenošću postiže, a ne na sama postignuća u čitanju i pisanju, ali se može prikazati i vrlo konkretno, da “adekvatna funkcionalna zdravstvena pismenost znači biti sposoban primijeniti umijeće pismenosti na zdravstvene materijale kao što su recepti, kartice za naručivanje, natpisi

na lijekovima i upute za kućnu njegu” [57]. Treba naglasiti da je „funkcionalna“ pismenost tek osnovni, najniži stupanj, a komunikacijska ili interaktivna te kritička pismenost viši su stupnjevi, koji progresivno omogućuju veću autonomiju pojedinca i osobnu osnaženost. Osim toga, progresija između tih stupnjeva ne ovisi samo o kognitivnom razvoju, već i o izloženosti različitim informacijama i porukama [52].

Ključni problem zdravstvene komunikacije je što općenito liječnici često nisu svjesni nesrazmjera između svog načina komuniciranja s pacijentima i pacijentove sposobnosti shvaćanja, pamćenja i djelovanja na osnovu dobivenih informacija [50]. Pokazuje se da je više od polovice pisanih materijala za pacijente preteško za prosječnog stanovnika SAD-a, a u odrasloj populaciji SAD-a čak je 20% funkcionalno nepismenih [58]. O tom nesrazmjeru samo u SAD-u svjedoči preko 300 studija [59]. Kod informacija u pisanom obliku uočava se nesrazmjer zdravstvene pismenosti pojedinca i razine čitkosti materijala namijenjenih pacijentima [59-63]. Istraživanja u svijetu pokazuju taj nesrazmjer kod različitih populacijskih skupina, također kod neengleskog govornog područja [64], s obzirom na različite zdravstvene teme te različite oblike prezentacije ili medije korištene za zdravstvene informacije [53]. Dakle, adekvatna čitkost pisanih materijala, odnosno prilagođena razina težine teksta specifičnoj ciljnoj populaciji, važna je ne samo kod prikupljanja podataka od ispitanika kako bi podaci bili vjerodostojni i usporedivi s drugim populacijama, već i kod informativnih materijala za edukaciju pacijenata te ključnih dokumenata koji jamče aktivnu ulogu pacijenta u odlučivanju o vlastitom zdravlju, kao naprimjer informirani pristanak, koji ima i zakonske posljedice. Stoga nije neuobičajeno da se razina čitkosti raznovrsnih pisanih materijala definira u određenim državama kao obvezujuća za određenu ciljnu populaciju ne samo kroz formulaciju lakorazumljivog teksta, već i kroz konkretnu mjeru čitkosti. Tako npr.

većina Amerikanaca ima sposobnost čitanja na razini 6. do 8. razreda, tj. stupanj čitalačke sposobnosti prosječnog Amerikanca iznosi 7,5 [65], a niska pismenost britanske populacije razlog je zašto se za zdravstvene informacije zahtijeva stupanj težine teksta po formuli  $SMOG \leq 5$  [66] kako bi takve informacije mogla razumjeti većina ljudi u Velikoj Britaniji. U Hrvatskoj se “Zakonom o zdravstvenoj zaštiti” iz 1993. godine [67], članak 25. stavak 6., jamči da pacijent ima “pravo na točno informiranje i poduku o svim pitanjima koja se tiču njegova zdravstvenog stanja” te se u Zakonu o zaštiti prava pacijenata iz 2004. godine [68] navodi da “pacijent ima pravo dobiti obavijesti na način koji mu je razumljiv s obzirom na dob, obrazovanje i mentalne sposobnosti”, a istovremeno jezična analiza tekstova za pacijente sa šećernom bolešću pokazuje da prosječno težak tekst, napisan na razini 12 godina školovanja, ne bi razumjelo skoro 80% stanovništva starijeg od 15 godina, prema popisu stanovništva iz 1991. godine [64], odnosno skoro 70% stanovništva prema popisu iz 2001. godine [69]. Stoga ne iznenađuju rezultati nedavnog istraživanja percepcije bolesti i kardiovaskularnih faktora rizika kod pacijenata sa šećernom bolešću u Hrvatskoj, koji pokazuju da je upravo slabo razumijevanje vlastite bolesti povezano s lošijim ishodima liječenja i zdravstvenim ponašanjem kod ove kronične bolesti [70].

U Hrvatskoj su podaci Državnog statističkog zavoda nakon popisa stanovništva 2001. godine pokazali vrlo nisku razinu obrazovanosti stanovništva. Nepismenih ima 1,8 %, a pismenom se smatra “osoba sa ili bez škole ako može pročitati i napisati sastavak u vezi sa svakidašnjim životom, odnosno koja može pročitati i napisati pismo bez obzira na kojem jeziku ili pismu može čitati odnosno pisati” [71]. Osim toga, pitanje o pismenosti u popisu stanovništva postavljeno je samo osobama koje se nisu školovale ili su imale završena manje od 4 razreda osnovne škole, jer se smatralo da je osoba

pismena ako je izjavila da zna pročitati i napisati neki uobičajeni tekst – pismo, a pritom je bilo svejedno na kojem jeziku ili pismu zna čitati i pisati. U svim popisima stanovništva rezultati o pismenosti dani su za stanovništvo staro 10 i više godina [71].  
 Obrazovanost odrasle populacije u Hrvatskoj vidi se iz tablice 1.

Tablica 1. Stanovništvo Republike Hrvatske starije od 15 godina prema završenom obrazovanju po spolu, prema popisu stanovništva 2001. godine (%) [71]

Obrazovanje	Ukupno	Muškarci	Žene
Bez škole	2,9	1,2	4,4
1-3 razreda osnovne škole	4,5	2,9	6,0
4-7 razreda osnovne škole	11,2	8,4	13,8
Osnovna škola	21,8	19,5	23,7
Srednja škola (ukupno)	47,1	54,6	40,2
- 1-3 god. (KV, VKV)	27,2	38,0	17,5
- ≥ 4 god.	15,0	13,0	16,9
- gimnazija	4,8	3,6	5,9
Viša škola	4,1	4,4	3,8
Fakultet, akademija, itd.	7,8	8,3	7,4
Nepoznato	0,7	0,7	0,6

Metodološki gledano, ovi podaci Državnog zavoda za statistiku [71] prikazani su prema sljedećim definicijama: "osnovna škola" odnosi se na sve osobe koje su završile osnovnu (osmogodišnju) školu, prijašnju osmoljetku ili sedmoljetku; "srednje škole" podijeljene su u tri osnovne grupe: škole za zanimanja u trajanju 1-3 godine i škole za KV i VKV radnike, škole za zanimanja u trajanju 4 i više godina, gimnazije.



Ako grupiramo gore navedene podatke, dobivamo sljedeće:  $\leq$ OŠ: 40,4%; SSS: 47,1%;  $\geq$ VŠS: 11,9%. Kod muške populacije, taj omjer iznosi:  $\leq$ OŠ: 32,0%; SSS: 54,6%;  $\geq$ VŠS: 12,7%, a kod ženske:  $\leq$ OŠ: 47,9%; SSS: 40,2%;  $\geq$ VŠS: 11,2%.

### **1.2.1. Testiranje zdravstvene pismenosti**

Ocjenu zdravstvene pismenosti odnosno pismenosti općenito ne može se provesti pukim izravnim postavljanjem pitanja ispitaniku da li je nešto razumio odnosno zna li čitati i pisati. Takav je postupak potpuno neučinkovit, jer ispitanici ne žele priznati nepismenost ili nerazumijevanje zbog srama i straha od poniženja [4,72]. Iako postoji povezanost između obrazovanja i pismenosti, ne može se s točnošću procijeniti stupanj čitalačke sposobnosti i razumijevanja samo na temelju stupnja obrazovanja [73,74]. Stoga su razvijeni instrumenti za testiranje čitanja i razumijevanja, odnosno instrumenti za ocjenu zdravstvene pismenosti. Za engleski jezik vrlo se često koriste testovi prepoznavanja riječi, REALM i WRAT. REALM (Rapid Estimate of Adult Literacy in Medicine) je praktični instrument za brzu procjenu zdravstvene pismenosti, a temelji se na prepoznavanju riječi koje se koriste u komunikaciji s liječnicima [74]. Testiranje traje do tri minute, može ga provoditi medicinsko osoblje bez posebnog obučavanja, a sastoji se od popisa 66 riječi različite dužine i težine izgovora [59]. Test je validiran, dobro korelira s ostalim instrumentima, a napravljena je i revidirana verzija REALM-R. Međutim, test je valjan za engleski jezik, a nije za jezike kao npr. španjolski zbog pravilnog fonemsko-grafemskog odnosa [75], a budući da je hrvatski jezik također ortografski transparentan, nije ga moguće primijeniti za ocjenu zdravstvene pismenosti na hrvatskom jeziku. WRAT (Wide Range Achievement Test) je također test

prepoznavanja riječi, koji se sastoji od 42 riječi rastuće težine, a prekida se nakon deset uzastopno pogrešno pročitanih riječi. WRAT ima velikih nedostataka pred testom REALM, jer je zaštićen autorskim pravima i nije besplatan, jer se za testiranje mora konzultirati priručnik s uputstvima, jer sadrži opće riječi, a ne iz medicinskog područja, te stoga što duže traje i ocjenjivanje je složenije [58]. Međutim, testovi prepoznavanja riječi, kojima se ocjenjuje sposobnost čitanja, ne jamče razumijevanje pisanog materijala. Za tu svrhu se koriste testovi razumijevanja, koji ocjenjuju koliko pacijent razumije pročitani materijal. Često korišteni test razumijevanja je „test Cloze“ [58], kojega je napravio Wilson Taylor 1953. godine [76], a naziv je dobio prema gestalovskom pojmu za “zatvaranje” odnosno način stvaranja potpune cjeline popunjavajući praznine u strukturi. Test Cloze se radi tako da se nakon uvodne rečenice u daljnjem tekstu svaka peta riječ zamijeni ravnom crtom identične dužine koja zamjenjuje tu riječ pa je ispitanici trebaju otkriti tako što će popuniti praznine u tekstu. Kao točna riječ računa se samo forma identična originalu, a rezultati testa govore koliko je tekst razumljiv tom ispitaniku. Na taj način test Cloze mjeri razumljivost na dva načina: koliko se znanja može dobiti iz teksta uokolo praznina, te koliko je dobro to usvojeno znanje iskorišteno za dobivanje dodatne informacije [58].

TOFHLA (Test of Functional Health Literacy in Adults) je test za ocjenu funkcionalne zdravstvene pismenosti u odrasloj populaciji, napravljen 1995. godine [57], a pored numeričke ocjene sadrži i ocjenu razumijevanja pročitano g teksta, koja se temelji na modificiranom testu Cloze. Teme tekstova odražavaju stvarne situacije unutar zdravstvenog sustava, kao npr. uputstva za pripremu za specijalističke pretrage, prava i obveze pacijenata unutar zdravstvenog osiguranja, standardizirani tekst informiranog pristanka i sl., da bi se procijenilo koliko dobro pacijenti mogu funkcionirati u

zdravstvenom okruženju. Čitkost pisanih materijala korištenih u testu TOFHLA iznosi 4,3; 10,4; te 19,5 prema formuli čitkosti Gunning Fog Indeks. Testiranje traje do 22 minute, ali je napravljena i skraćena verzija, S-TOFHLA [77], koja ne oduzima više od 12 minuta. Obje su verzije istovremeno rađene za engleski i za španjolski jezik [59]. U novije vrijeme napravljena je modificirana verzija za hebrejski jezik [78]. Test TOFHLA i njegova skraćena verzija S-TOFHLA korišteni su u brojnim studijama koje pokazuju povezanost zdravstvene pismenosti s različitim aspektima kvalitete zdravstvene zaštite, pristupačnosti zdravstvenom sustavu, korištenju zdravstvene zaštite, troškovima, te zdravlju, ishodu liječenja, zadovoljstvu i sl. kod različitih grupacija pacijenata [59,74]. S druge strane, ističe se kako se testiranje zdravstvene pismenosti još uvijek dovoljno ne koristi u kliničkoj praksi, ali i da je potreban razvoj još boljih testova [1].

### **1.3. Čitanje i čitalačka sposobnost**

Za objašnjenje težine određenog pisanog materijala potrebno je uzeti u obzir oba aspekta, tj. sam tekst, kako je napisan i koje sve elemente sadrži, te čitalačke sposobnosti osobe koja taj tekst čita. To obuhvaća i objašnjenje samog procesa čitanja: što čitanje jest, koji čimbenici utječu na čitanje, te po čemu se razlikuju dobri i loši čitači. Postoje brojne teorije čitanja, što govori kako je čitanje složen proces te je vrlo teško opisati što se to događa i što radimo dok čitamo. Pretpostavka je da čitanjem dolazimo do značenja teksta kroz proces interakcije s pisanom riječi. Istraživanja o čitanju se razlikuju s obzirom na to da li se temelje na samom procesu čitanja ili na proizvodu čitanja [79]. Čitanje obuhvaća vještine prepoznavanja riječi, brzine čitanja

odnosno tečnosti, te vještine razumijevanja kroz rješavanje problema. Pritom treba naglasiti da se razumijevanje shvaća kao vještina odvojena od samog čitanja, tj. kao lingvistička vještina, jer do razumijevanja dolazi prilikom prezentacije materijala kroz različite modalitete, uključujući i govor, ali se razumijevanje može shvatiti i kao vještina odvojena od jezika, kao općekognitivna vještina rješavanja problema. Međutim, različiti su pristupi ovom problemu kroz povijest. Tako Thorndike [80] početkom 20. stoljeća čitanje objašnjava kao „rezoniranje“ ili zaključivanje, a dobri čitači su oni koji mogu jasno razmišljati. Tradicionalni bihevioralni pristup procesu čitanja, koji je bio popularan 40-tih i 50-tih godina 20. stoljeća, vidi čitače kao pasivne osobe koje dekodiraju pisanu riječ na razini grafema, fonema, sintakse i semantike. Shematska teorija objašnjava stjecanje znanja i tumačenje teksta aktivacijom shema, koje su ustvari mreže informacija pohranjene u mozgu, a služe kao filtri za dolazeće informacije. Goodman [81] zato čitanje naziva „psiholingvističkom igrom pogađanja“, gdje čitači pogađaju ili predviđaju značenje teksta na temelju minimalnih tekstualnih informacija i maksimalnog korištenja postojećeg, aktiviranog znanja. Smith [82] govori o nevizualnoj vrsti informacija koje nadilaze razinu pisanog teksta, a uključuju čitačevo čitalačko iskustvo, poznavanje konteksta, poznavanje struktura i obrazaca jezika i vrsta teksta, kao i opće poznavanje svijeta i određene teme. Novija istraživanja pokazuju da je za tečno čitanje neophodno automatizirano prepoznavanje riječi kako bi se oslobodio kapacitet pažnje za razumijevanje [83]. Gruba procjena optimalne brzine čitanja iznosi 250-300 riječi u minuti [84]. Uočene su razlike između dobrih i loših čitača s obzirom na proces i na proizvod čitanja. Tako loši čitači sporo čitaju, doslovno shvaćaju pročitane riječi, preskaču neke riječi, ne shvaćaju kontekst, brzo se umaraju čitajući, te ne razumiju pročitano. S druge strane, dobri čitači tečno čitaju, znaju pronaći pomoć za nepoznate riječi, shvaćaju kontekst, uporni su u čitanju i znaju protumačiti značenje

riječi [58]. Tečni čitači tijekom čitanja procesuiraju otprilike 80% leksičkih i 40% funkcionalnih, gramatičkih riječi, a ne samo da tečno čitaju, nego su i precizni u čitanju, tj. njihovo je čitanje točno [79]. Poteškoće u čitanju zbog nepoznatih riječi negativno utječu na razumijevanje pa je potrebno da čitači poznaju 95% riječi nekog teksta kako bi ga adekvatno razumjeli te kako bi mogli predvidjeti značenje nepoznatih riječi iz konteksta [85,86]. Procjena je za engleski jezik [87] da osoba mora vladati vokabularom od otprilike pet tisuća riječi da bi bila u stanju razumjeti 97% riječi uobičajenog teksta, a ako vlada sa samo dvije tisuće najučestalijih riječi, razumjet će tek 90% teksta. Pored navedenih osobina čitača, na uspješnost čitanja utječu i dob, spol, zanimanje, inteligencija, društveni sloj, obrazovanje i drugi čimbenici. S druge strane, sam tekst ima određene čimbenike koji olakšavaju ili otežavaju čitanje: organizacija i kohezija teksta, tema i sadržaj, vrsta odnosno žanr teksta, tipografske i lingvističke osobine, čitkost, itd. Za očekivati je da će jezici s transparentnom ortografijom biti čitkiji od onih s netransparentnom ortografijom, kakav je engleski jezik [79]. Težina vokabulara svakako utječe na razumijevanje, a može se izraziti kroz dužinu i frekvenciju riječi. Dužina riječi, za engleski jezik, ugrubo je i povezana s frekvencijom riječi; najfrekventnije riječi su obično kraće [79]. Chall, autor jedne od formula čitkosti, navodi da je težina vokabulara ustvari najznačajniji prediktor težine teksta [88]. Također, na razini rečenice, pokazuje se da su kraće rečenice sintaktički jednostavnije [79], što znači da će biti i razumljivije. Postoji visoka korelacija između čitkosti teksta mjereno testovima razumijevanja na ispitanicima, kao naprimjer testom Cloze, te mjereno formulama čitkosti [80]. Moglo bi se reći da je preporuka za mjerenje težine odnosno čitkosti teksta stručna procjena panela stručnjaka, a ako to nije dostupno, primjena neke od formula čitkosti [89].

## 1.4. Čitkost i formule čitkosti

Ukratko, formula čitkosti je objektivna procjena težine teksta [90], a čitkost se može definirati kao „jednostavnost razumijevanja kao posljedica načina pisanja“ [91] ili kao „jednostavnost čitanja riječi i rečenica“ te je jedna od osobina jasnoće teksta [92]. Formula čitkosti je ustvari matematička jednadžba dobivena regresijskom analizom, a predstavlja procjenu težine odnosno kompleksnosti teksta prvenstveno za čitanje, ali i za razumijevanje. Razina čitkosti se izražava ili brojem koji predstavlja težinu samog teksta ili brojem koji predstavlja stupanj obrazovanja koji je potreban da se razumije tekst, uz vrlo visoku preciznost predviđanja. Još 20-tih godina 20. stoljeća pedagozi su otkrili način kako korištenjem težine vokabulara i dužine rečenice predvidjeti razinu težine teksta. Tu su metodu uklopili u formulu koja pokazuje čitkost teksta, a njihov uspjeh se potvrdio primjenom formule više od 80 godina. Istraživanja na tom području te daljnji napredak pokrenut je ponovno 50-tih godina, kada se razvijaju nove formule, a njihova primjena se počinje naširoko koristiti u novinarstvu, znanosti, zdravstvu, pravu, osiguranju, te u industriji, a zatim i u vojsci SAD-a [90]. U literaturi se spominje preko 40 različitih formula čitkosti, koje nude prilično točan stupanj težine teksta [58], otprilike  $\pm 1-1,5$  stupanj točnosti, a prilično dobro koreliraju međusobno, iako razlike mogu biti 1-2 stupnja među različitim formulama [56]. Najčešće validirane formule su one na engleskom jeziku, a postoje modifikacije formula za barem još 12 jezika, kao npr. njemački, španjolski, francuski, nizozemski, danski, kineski, ruski, švedski, vijetnamski, korejski, hindu, hebrejski, itd. [58,93]. Istraživanja formula čitkosti i njihovih primjena na druge jezike dovela je do saznanja da je npr. engleski čitkiji od francuskog, a francuski čitkiji od španjolskog. To znači da se i brojčani rezultati formula moraju modificirati ovisno o jeziku teksta koji se analizira [94].

Među najčešće spomenutim i korištenim formulama čitkosti, mogu se izdvojiti: Flesch Reading Ease (FRE) Score, Flesch-Kincaid Grade Level Index, SMOG, Fog Test, Fry Formula te Dale-Chall Formula. Ostale formule koje se spominju u literaturi, a također su opisane u daljnjem tekstu disertacije, pojavljuju se pod sljedećim nazivima: Coleman-Liau, FORCAST, ARI (Automated Readability Index) [90], Lix [93], SOL [94], Flesh-Vacca, GulpEase [95], itd.

#### **1.4.1. Polazište i razvoj formula čitkosti**

Sredinom 19. stoljeća nastavnici u SAD-u su uočili da njihovi učenici uče čitati korak po korak, a najbolje nauče iz materijala koji su napisani na njihovoj razini čitanja. Tako je nastalo promicanje različitih razina čitanja za svaki razred uz pomoć standardiziranih testova čitanja. Autori William A. McCall i Lelah Crabbs [96] publicirali su materijale za učenje temeljene na standardiziranim testovima, a to je postala važna mjera čitalačke sposobnosti učenika u SAD-u. Ti i kasnije napravljeni testovi mjere razumijevanje tako što učenici najprije pročitaju odlomak, a zatim odgovaraju na pitanja s višestrukim odgovorima. Testovi McCall-Crabb su također postali važni u razvoju i validaciji formula čitkosti [90]. Testiranje odrasle populacije počelo je 1937. godine u Chicagu, a rezultati su pokazali da opća populacija SAD-a ima vrlo ograničenu čitalačku sposobnost, odnosno da s uživanjem čitaju samo najjednostavnije tekstove, najčešće jeftine romane i novinske vijesti popraćene grafičkim ilustracijama. Kasnije je američka vojska najviše ulagala u takva istraživanja, naročito proučavajući pismenost na radnom

mjestu pa je 50-tih godina 20. stoljeća prolaz na testu pismenosti bio uvjet pristupanja vojnoj službi [90].

Prve studije čitkosti nastojale su pronaći praktične metode kojima bi se materijali za čitanje uskladili sa čitalačkim sposobnostima učenika i odrasle populacije. Tragali su za jednostavno primjenjivim formulama čitkosti koje će u svojoj praksi koristiti nastavnici i knjižničari. Lucius Adelno Sherman krajem 19. stoljeća primjećuje kako se u tekstovima tijekom vremena koriste sve kraće i kraće rečenice. Analizirao ih je statistički brojeći prosječnu dužinu rečenice, koja je u njegovo vrijeme iznosila 23 riječi po rečenici [97], a u današnje vrijeme iznosi 20 riječi po rečenici [90]. Na temelju Shermanovih rezultata moglo se zaključiti da je pisani tekst moguće statistički analizirati, da kraće rečenice i konkretni pojmovi povećavaju čitkost teksta, da je usmeni govor učinkovitiji od pisanog te da tijekom vremena pisani govor postaje učinkovitiji što više nalikuje na usmeni govor. Sherman također pokazuje kako su pojedini autori tekstova dosljedni u prosječnoj dužini rečenica koje koriste te je upravo ta dosljednost postala osnova za korištenje uzoraka tekstova za procjenu čitkosti, a ne cijelih tekstova [90]. Sherman je prvi koristio statističku analizu u svrhu analize čitkosti, ali njegovo je važno otkriće i opažanje da tijekom vremena rečenice ne samo da postaju kraće, već i jednostavnije i manje apstraktne, što je posljedica procesa korištenja jasnih i jakih rečenica u usmenom govoru kroz tisućljeća u svrhu usavršavanja učinkovitog komuniciranja [97].

Dvadesetih godina 20. stoljeća nastaju znanstveni alati za proučavanje i objektivno mjerenje edukacijskih problema. Jedan od takvih alata je opsežan popis riječi engleskog jezika po učestalosti, psihologa Edwarda L. Thorndikea, gdje se uočava da su češće



riječi poznatije i jednostavnije, a što više odrastamo i učimo, tako izgrađujemo naš vokabular i lakše savladavamo duže i složenije rečenice [90]. Testiranje vokabulara kroz provjeru značenja riječi je najjači prediktor verbalnog i apstraktnog intelektualnog razvoja. Značenje riječi je oduvijek bila jaki pokazatelj razvoja čitatelja, razumijevanja čitanja te verbalne inteligencije, tako da vokabular predstavlja jaki prediktor težine teksta [98]. Riječi koje prve naučimo su najjednostavnije i najkraće, a ujedno se pokazuje da su i najčešće. Johnson [99] je pokazao da je 10 najčešćih riječi u njegovim analizama pokrivalo 25% ukupno korištenih riječi, a Fry [100] pokazuje da 100 najčešćih riječi pokriva skoro 50% teksta, odnosno 300 najčešćih riječi pokriva oko 65% teksta.

Do pojave računala, za procjenu težine tekstova za čitanje najčešće su se koristili popisi riječi po učestalosti. Tako je Thorndikeovo istraživanje postalo osnova za razvoj prvih formula čitkosti. Nakon njega uslijedilo je opsežno istraživanje vokabulara, koje je kulminiralo radom Georgea Kingsleya Zipfa [101]. Zipf je statističkom analizom jezika pokazao kako načelo najmanjeg truda funkcionira u govoru ljudi. Pokazao je da u mnogim jezicima postoji matematički odnos između teških i lakih riječi, što je nazvano Zipfova krivulja [90]. Taj pojam očuvanja energije je središnja karakteristika jezika i osnovno je polazište za istraživanje frekvencija riječi. Klare [102] zaključuje da ljudi ne samo da češće koriste neke riječi, nego te riječi brže i prepoznaju, više ih vole, lakše ih razumiju i brže ih uče.

Prvu formulu čitkosti publicirali su Bertha Lively i S.L. Pressey u članku iz 1921. godine za tekstove za djecu [103]. Tom se formulom mjerio broj različitih riječi na svakih tisuću riječi te broj riječi koje nisu bile na Thorndikeovom popisu. Uslijedila je

formula autora Mabel Vogel i Carleton Washburne [104], koja uključuje četiri faktora i preteča je modernih formula čitkosti. William S. Gray i Bernice Leary [105] su najprije utvrdili 228 elemenata koji utječu na čitkost teksta, a zatim su statističkom analizom utvrdili 5 najvažnijih elemenata koje su uključili u svoju formulu čitkosti. To je pokrenulo cijeli niz potraga za najsavršenijom formulom, koristeći različite kombinacije varijabli stila. Pedesetih godina 20. stoljeća postojalo je 25 formula za dječju literaturu te 14 formula za tekstove za odrasle, a osamdesetih godina postojalo je preko 200 formula čitkosti. Ovo dugogodišnje istraživanje čitkosti rezultiralo je zaključkom da su najbolji prediktori težine teksta upravo težina vokabulara i prosječna dužina rečenice [90].

## **1.4.2. Formule čitkosti za engleski jezik**

### **1.4.2.1. Formula “Flesch Reading Ease” (FRE)**

Najčešće korištena kompjutorizirana formula čitkosti je formula “Flesch Reading Ease” (FRE), nazvana po autoru Rudolfu Fleschu, američkom državljaninu austrijskog porijekla, koji je u ozračju demokratizacije obrazovanja u Americi izradio formulu koja je trebala pomoći u određivanju težine udžbenika za djecu kako bi se djeci olakšalo učenje. Sam autor svoje područje istraživanja naziva “znanstvena retorika”, a svoju formulu jednostavnom mjerom, koja se ipak treba smatrati kao gruba procjena težine teksta [106]. Osim u području obrazovanja, ova je formula doživjela velik uspjeh u području novinarstva, za koje Flesch nudi pregršt savjeta u svojoj knjizi o umijeću čitkog pisanja, “The Art of Readable Writing” [106], s temeljnom idejom da treba pisati

onako kako se govori, kako bi se privuklo šire čitateljstvo. Taj naglasak na stilu podupire i činjenicom da osim čitkog odnosno jednostavnog pisanja treba voditi računa i o zanimljivosti pa nudi i formulu za izračunavanje zanimljivosti teksta [106]. Treba napomenuti da je Flesch svoju prvu formulu čitkosti objavio 1943. godine u svojoj disertaciji o osobitostima čitkog stila, "Marks of a Readable Style" [107], a kasnije ju je modificirao uzevši u obzir vrlo visoku čitkost direktnih razgovora u pisanim materijalima te izostavivši složene pokazatelje osobnosti, kao npr. vlastita imena i posvojne zamjenice, te izostavivši varijablu sufiksa, zbog kojih je prvotna formula nailazila na kritike [108]. Revidirana formula je pojednostavljena te je postala najkorištenija formula čitkosti izvan obrazovnog sustava [108]. Često se koristi za tekstove namijenjene pacijentima, jer testira koliko se tekst može razumjeti, a zatim i djelovati na osnovu shvaćenih informacija [108,109]. Formula se temelji na standardnim tekstovima za testiranje čitanja autora McCalla i Crabbsa uz 75%-tni stupanj razumijevanja. Svedena je na dvije varijable, prosječnu dužinu riječi i prosječnu dužinu rečenice, te glasi:

$$FRE = 206,835 - 0,846 wl - 1,015 sl [57]$$

gdje je  $wl$  = dužina riječi izražena brojem slogova (engl. "word length"), a  $sl$  = dužina rečenice izražena brojem riječi (engl. "sentence length")

Čitkost pisanih tekstova ovom se formulom izražava na ljestvici od 0 do 100, gdje se pojedina kategorija težine objašnjava deskriptivno, te je 0 indeks najveće težine, a 100 indeks jednostavnosti odnosno lakoće teksta. Grafički prikazano za svaku kategoriju, tablica 2. daje i stupanj obrazovanja koji osoba mora imati da bi razumjela tekst te

postotak odrasle populacije koja bi razumjela tekstove određene težine, prema procjeni samog autora formule iz 1949. godine [106]:

Tablica 2. Skala indeksa po formuli FRE

FRE	Opis stila	Procjena završenog stupnja obrazovanja	Procjena udjela odrasle populacije SAD-a (%)
90 – 100	vrlo lako	4 razreda	93
80 – 90	lako	5 razreda	91
70 – 80	donekle lako	6 razreda	88
60 – 70	standardno	7 ili 8 razreda	83
50 – 60	donekle teško	nešto srednje škole	54
30 – 50	teško	srednja ili viša škola	33
0 – 30	vrlo teško	viša škola	4,5

Flesch naglašava da, iako vrijednost 100 predstavlja 100%-tnu čitkost, čitkost ne možemo izražavati postotkom, nego će vrijednost 100 praktično značiti da je tekst razumljiv osobama koje su završile 4 razreda škole pa se jezikom popisa stanovništva mogu smatrati funkcionalno pismenima [106]. Radi što jednostavnijeg određivanja težine teksta, Flesch je osim formule ponudio i grafički oblik, nomogram, koji se sastoji od ukupno tri stupca, pri čemu jedan stupac sadrži brojčanu skalu ukupnog broja riječi u rečenici, drugi stupac sadrži brojčanu skalu broja slogova na 100 riječi, a središnji stupac nudi rezultat formule izražen kroz indeks formule i opis stila [106]. U današnje je

vrijeme Fleschova formula sastavni dio izračuna čitkosti u računalnim programima za obradu teksta te stoga još više dobiva na popularnosti.

#### **1.4.2.2. Formula “Flesch-Kincaid”**

Formula “Flesch-Kincaid” ili “Flesch-Kincaid Grade Level” se temelji na Fleschovoj formuli, ali se indeks čitkosti izražava doslovno kao razred škole, po američkom sustavu školovanja, u kojem bi učenik trebao biti da razumije tekst, odnosno, šire gledano, godinama školovanja koje su potrebne da bi čitatelj bez poteškoća pročitao i razumio određeni tekst [90]. Upravo je ovaj način izražavanja težine teksta bio cilj autorima formule da na jednostavniji i praktičniji način izraze Fleschove opise stilova u rasponu od 0 do 100. Učinili su to za vojne potrebe, jer ih je angažirala američka mornarica, koja je zatim formulu koristila za svoje tehničke materijale. Autori su formulu objavili 1975. godine [110], a osim u vojne svrhe, vrlo se brzo počela koristiti u području obrazovanja, jer su učitelji i knjižničari puno jednostavnije mogli odrediti težinu određene knjige ili drugih pisanih tekstova. Ova se formula također koristi za zdravstvene informacije i za priručnike za samostalno čitanje.

Kao i kod Fleschove formule, kao osnova se koristi broj slogova po riječi i broj riječi u rečenici, ali je konačni indeks broj koji označava broj razreda škole. Formula “Flesch-Kincaid” glasi:

$$\text{broj razreda} = (0,39 \times \text{ASL}) + (11,8 \times \text{ASW}) - 15,59$$

odnosno pojednostavljena verzija glasi:

$$\text{broj razreda} = (0,4 \text{ ASL}) + (12 \text{ ASW}) - 15$$

gdje je ASL = prosječna dužina rečenice (engl. “average sentence length”), koja se računa tako da se podijeli ukupni broj riječi s ukupnim brojem rečenica, a ASW = prosječni broj slogova po riječi (engl. “average number of syllables per word”), koji se računa tako da se podijeli ukupan broj slogova s ukupnim brojem riječi u testiranom uzorku [90].

Formula “Flesch-Kincaid” je validirana na vojnim materijalima na engleskom jeziku na tadašnjim polaznicima mornarice, a u današnje vrijeme je, kao i Fleschova formula, sastavni dio izračuna čitkosti u računalnim programima za obradu teksta.

#### **1.4.2.3. Formula SMOG**

Formula SMOG, osim što nazivom asocira na “smog”, odnosno nešto nejasno ili nečisto pa time i nečitko, kratica je za “Simple Measure of Gobbledygook” (jednostavna mjera besmislenog blebetanja). Objavio ju je 1969. godine G. Harry McLaughlin [111]. To je ručna metoda testiranja čitkosti i smatra se brzom, dosljednom i jednostavnom [109]. Dobiveni indeks je broj godina školovanja koje su potrebne da bi čitatelj bez poteškoća mogao pročitati, a zatim i razumjeti, određeni tekst [111]. Ova se formula vrlo često koristi za analizu zdravstvenih informacija. Neki autori prigovaraju da je dosadno brojiti točan broj slogova te da ova formula nije primjerena za stupanj obrazovanja ispod 6 razreda [109]. Međutim, za razliku od drugih formula, kojima se za iste tekstove dobivaju niži indeksi čitkosti, ova formula se temelji na rezultatima testova uz uvjet

100%-tne točnosti odgovora pa se može reći da predviđa izrazito visoko razumijevanje teksta.

Formula SMOG sastoji se od četiri koraka i računa se na sljedeći način [111]: 1) izaberu se tri uzorka teksta, od kojih svaki čini 10 uzastopnih rečenica, iz tri različita dijela pisanog materijala (ukupno barem 100 riječi); 2) izračuna se ukupan broj riječi sa tri ili više slogova u tih 30 rečenica; 3) izračuna se drugi korijen od dobivenog broja; 4) doda se broj 3. Kada tekst koji želimo testirati sadrži manje od 30 rečenica, formula SMOG se računa na sljedeći način: 1) izračuna se broj svih višesložnih riječi u tekstu; 2) izračuna se ukupni broj rečenica; 3) izračuna se prosječni broj višesložnih riječi po rečenici; 4) pomnoži se dobiveni prosjek s brojem rečenica koliko ih nedostaje do 30; 5) dobiveni broj se zbroji s ukupnim brojem višesložnih riječi; 6) izračuna se drugi korijen od dobivenog broja, a zatim doda broj 3 [109].

Umjesto tekstualnog objašnjenja računanja formule SMOG, koji se najčešće koristi u literaturi, pojavljuje se i oblik jednadžbe koji je pregledniji, a glasi:

$$\text{SMOG} = 3 + \sqrt{3^+ \text{ sloga}}$$

te predstavlja skraćenu, praktičnu varijantu jednadžbe koju daje sam autor na temelju svog preciznog izračuna koji glasi [111]:

$$\text{SMOG} = 3,1291 + 1,0430 \times \sqrt{3^+ \text{ sloga}}$$

Budući da standardna pogreška izračunata za procjenu čitkosti pojednostavljenom formulom iznosi 1,5, što govori da će se točno procijeniti stupanj školovanja za

određeni tekst u rasponu od 1,5 razreda u 68% slučajeva [111], preciznije je koristiti izvornu, složeniju formulu. Sam autor tvrdi kako se njegovom formulom puno brže računa čitkost teksta nego Fleschovom formulom, jer nije potrebno brojiti baš svaki slog u tekstu da bi se dobila mjera semantičke težine teksta. Otkriva kako je otkrio zakon odnosa broja slogova u tekstu i višesložnih riječi, koje definira kao riječi od tri i više slogova, a koji govori da se ukupan broj slogova na sto riječi može izračunati tako da se pomnoži broj višesložnih riječi sa tri i doda broj 112. Također izdvaja dva bitna polazišta, koja je kasnije testiranjem i potvrdio, a to su: 1) da je broj višesložnih riječi u točno određenom broju rečenica točan pokazatelj relativne težine različitih tekstova, te 2) da formula kojom se broj višesložnih riječi pretvara u broj razreda tj. godina školovanja daje prihvatljive rezultate.

McLaughlin objašnjava postupak koji je primijenio kako bi došao do ove vrlo jednostavne formule regresijskom analizom, koristeći odlomke iz testa čitanja autora McCalla i Crabbsa [112] te kako je metodom pokušaja i pogrešaka ustanovio da je kvadriranje višesložnih riječi jednostavniji postupak od prethodnih složenih formula drugih autora [111]. Naravno, vodio se originalnom idejom Roberta Gunninga [113] da broj višesložnih riječi može poslužiti kao mjera semantičke težine teksta. Tome je pridodao svoje otkriće da najveću prediktivnu vrijednost imaju dužina riječi i dužina rečenice. Pokazao je da je dužina riječi pokazatelj semantičke, a dužina rečenice pokazatelj sintaktičke težine teksta [114]. Na primjeru engleskog jezika, pokazao je da je dužina riječi povezana s preciznošću vokabulara pa čitatelj mora obično uložiti dodatni napor kako bi otkrio puno značenje dugačkih riječi. S druge strane, dugačke rečenice skoro uvijek imaju složenu gramatičku strukturu, što iziskuje napor čitatelja i predstavlja dodatni pritisak na njegovu radnu memoriju, jer se nekoliko dijelova svake



rečenice mora zadržati u memoriji da bi ih se kasnije moglo kombinirati u smislenu cjelinu [111]. U svojoj formuli McLaughlin kao bazu koristi 30 rečenica, jer je otkrio da je upravo 30 rečenica najprikladnija veličina za izračunavanje čitkosti teksta, a uzorci od 100 riječi nisu dovoljno pouzdani, jer nisu karakteristični za ukupni tekst koji se testira. Predlaže uzimanje uzoraka iz različitih dijelova teksta, kako bi se povećala pouzdanost rezultata čitkosti za cjelokupni tekst. Kao prednost svoje formule, također naglašava činjenicu da je kao pokazatelj težine čitanja izrazio stupanj školovanja, odnosno razred, koji je pokazao potpuno razumijevanje, za razliku od autora ostalih formula koji su se zadovoljili određenim postotkom razumijevanja, obično između 50 i 75%. On smatra da manji postoci razumijevanja određenog teksta koji su uzeti kao osnova za te formule samo pokazuju da će točni odgovori testiranja razumijevanja previše ovisiti o prirodi samih pitanja. Tako je formula SMOG nastala kao jednadžba dobivena regresijskom analizom koja u odnos stavlja višesložne riječi svakog testiranog teksta i prosječni stupanj školovanja učenika koji su točno odgovorili na sva pitanja testa [111].

Ova vrlo često korištena i citirana formula čitkosti modificirana je za španjolski i francuski jezik, za koje autori modifikacije tvrde da su manje čitki jezici, jer su indeksi čitkosti prijevodnih tekstova bili puno viši nego za engleski jezik. Kao suprotnost značenju riječi “smog” u engleskom jeziku, a u želji da ponude nešto pozitivno za ove dvije mediteranske zemlje, svoju su formula nazvali “sol”, asocirajući na sunce [94].

#### **1.4.2.4. Formula “Fog Test”**

Formulu „Fog Test“ ili „Gunning Fog Index“ ponudio je Amerikanac Robert Gunning 1952. godine [113], a zbog svoje jednostavnosti postala je odmah vrlo popularna. Dobila je naziv po engleskoj riječi “fog”, što znači “magla”, jer je autor htio naglasiti kako nepotrebno složen način pisanja zamagljuje razumijevanje [90]. Prvenstveno se koristi u obrazovanju, može se izračunati ili kompjutorski ili ručno, a rezultat testa se interpretira kao godine školovanja odnosno broj razreda koji je potreban da bi čitatelj mogao razumjeti određeni tekst čitajući ga prvi put. Formula uzima u obzir dvije varijable, prosječnu dužinu rečenica i višesložne riječi, koje autor definira kao riječi koje imaju više od dva sloga, na svakih sto riječi. Računanje Gunningove formule “Fog Index” prikazuje se u literaturi na nekoliko načina, vrlo općenito [90], vrlo detaljno [115] te opisno koristeći algoritam [115]:

$$\text{broj razreda} = 0,4 \times (\text{prosječna dužina rečenice} + \text{višesložne riječi}) \quad [90]$$

odnosno detaljno za praktičnu primjenu,

$$\text{broj razreda} = 0,4 \times ((w / s) + 100 \times (3^+w / w)) \quad [115]$$

gdje je  $w$  = ukupan broj riječi;  $s$  = ukupan broj rečenica, a  $3^+w$  = broj riječi s više od dva sloga)

odnosno kroz opis postupka [115]:

1. odaberite cijeli odlomak teksta s oko 100 riječi ukupno
2. izračunajte prosječnu dužinu rečenice (podijelite broj riječi s brojem rečenica)

3. prebrojite riječi s tri ili više slogova, ne računajući vlastita imena, jednostavan žargon ili riječi složenice, kao ni česte nastavke kao što su “-es”, “-ed”, “-ing”.
4. zbrojite prosječnu dužinu rečenice i postotak višesložnih riječi.
5. pomnožite dobiveni rezultat sa 0,4.

Kao što se vidi iz točke 3. opisanog postupka računanja formule, ova je formula namijenjena tekstovima na engleskom jeziku, a zbog tih posebnih pravila računanja višesložnih riječi, jer se dio sufiksa ne uzima u obzir, nije jednostavno prilagodljiva drugim jezicima. Osim toga, izvorna Gunningova formula bila je još zahtjevnija, jer su se pojedini dijelovi rečenica koji su bili jedna smisljena cjelina računali kao jedna rečenica pa se čitkost računala na nizu relativno kratkih rečenica. Autorov pristup takvom računanju rečenica potjecao je iz pretpostavke da čitatelji takve smisljene cjeline doživljavaju kao cjelovite odnosno dovršene misli, a svrha formule je ionako da izrazi jasnoću zamišljanja unutar rečenica. Ovakvo računanje se ipak napustilo 80-tih godina 20. stoljeća te su nastala jednostavnija uputstva.

Gunningova formula se temelji na 90%-tnoj točnosti rješavanja testa razumijevanja te zajedno s formulom SMOG daje vrlo visoku točnost procjene čitkosti teksta, ali su im i dobiveni indeksi nešto viši nego kod računanja drugim formulama. Preporučuje se da indeks čitkosti po formuli “Fog Index” bude ispod 12 ako se koristi za širu populaciju, a kad je potrebno da tekst razumiju skoro svi, da indeks bude ispod 8 [90].

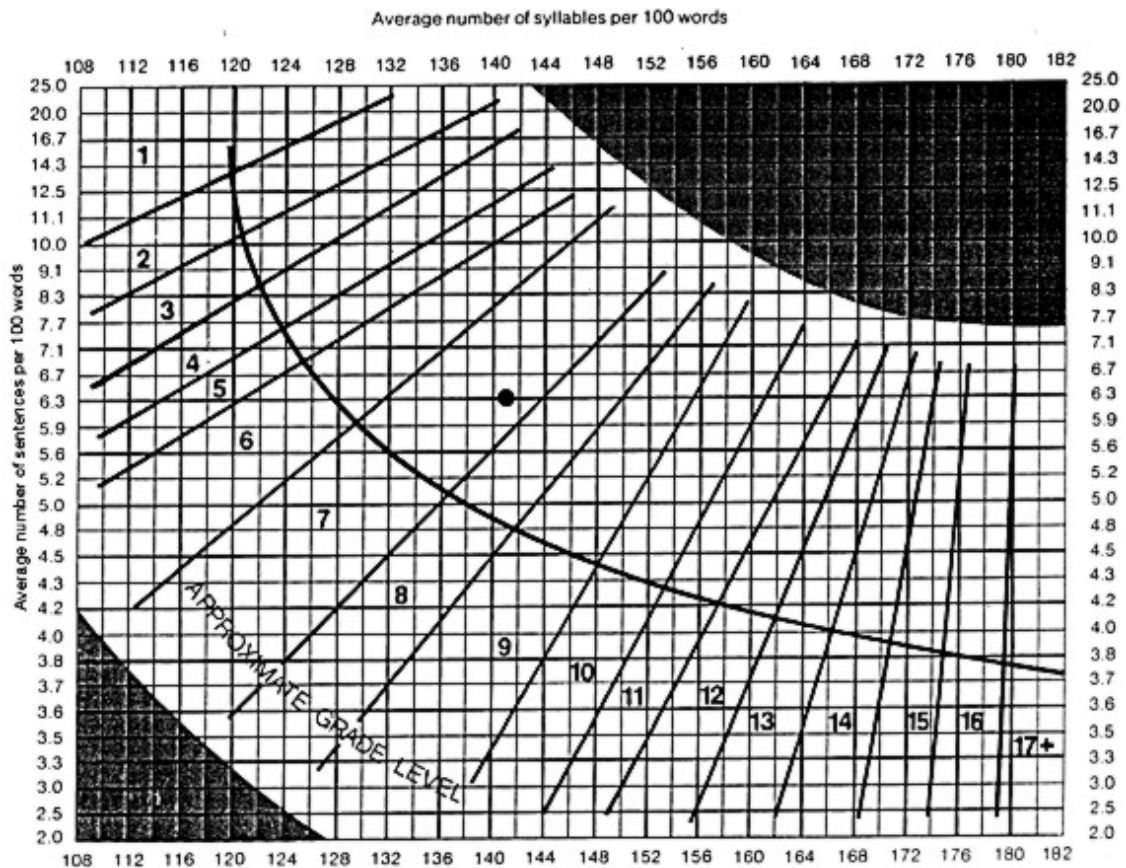
#### **1.4.2.5. “Fry Formula”**

“Fry Formula” je objavljena 1968. godine [116], autor joj je Edward Fry, nije zaštićena autorskim pravima pa se vrlo često koristi i za testiranje zdravstvenih informacija. Primjerena je za procjenu težine teksta za školovanje u trajanju od 1 do 17 godina, a za točnost procjene zahtijeva uzorak teksta od samo 100 riječi [58]. Računa se ručno, a uz formulu postoji i pripadajući grafikon, “Fry Chart”, koji nudi jednostavan način očitavanja rezultata testa, a može se naći na stranicama Interneta [38,58]. Uputstva za računanje ove formule glase [90]:

1. odaberite uzorak teksta od 100 riječi
2. pronađite na osi y na grafikonu prosječan broj rečenica za odlomak od 100 riječi
3. pronađite na osi x na grafikonu prosječan broj slogova za odlomak od 100 riječi
4. sjecište ovih dviju koordinata pokazuje indeks čitkosti

Edward Fry je svoj grafikon najprije razradio za tekstove srednjoškolske težine, zatim ga je 1969. godine proširio za osnovnu školu, a 1977. godine i za visokoškolsko obrazovanje [90].

Grafikon, koji uključuje sve tri razine obrazovanja, izgleda ovako [90]:



Zatamnjena područja grafikona prikazuju vrijednosti koje nisu valjane.

#### 1.4.2.6. Formula “Dale-Chall”

Formula “Dale-Chall” je objavljena 1948. godine [117], ali je vrlo složena i koristi popis tri tisuće riječi koje su se tada smatrale teškima, što nije toliko primjereno analizi suvremenih tekstova [109]. Stoga su autori revidirali popis riječi 1995. godine [98], ali računalni programi nisu revidirani te je potrebno ručno računanje uz konzultaciju pravila i popisa riječi iz njihova priručnika [90], što ovu formulu ne čini nimalo atraktivnom za računanje čitkosti tekstova.

#### 1.4.2.7. Formula “Coleman-Liau Index”

Ova je formula čitkosti objavljena 1975. godine, a autori su joj Meri Coleman i T.L. Liau. Indeks čitkosti pokazuje stupanj školovanja koji bi čitatelj trebao imati kako bi mogao razumjeti pročitani tekst. Za razliku od prethodno opisanih formula čitkosti, ova se formula ne zasniva na broju slogova u riječima, već na broju znakova odnosno slova u riječima. Iako postoje sumnje o točnosti rezultata takve formule kojom se broje znakovi, pokazuje se da računalni programi točnije računaju broj znakova nego broj slogova u riječima te su takvi program dostupniji [115].

Uputstva za računanje ove formule glase [115]:

1. podijelite broj znakova s brojem riječi te pomnožite s 5,89. Nazovimo to A.
2. broj rečenica u odlomku od 100 riječi pomnožite s 0,3. Nazovimo to B.
3. oduzmite B od A i umanjite za 15,8.

Također, ova se formula pojavljuje i u obliku jednadžbe [115]:

$$CLI = 5,89 \times (ch / w) - 0,3 \times (s / w) - 15,8$$

gdje je CLI = “Coleman-Liau Index”; ch = ukupan broj znakova; w = ukupan broj riječi;  
s = ukupan broj rečenica u odlomku od 100 riječi.

#### **1.4.2.8. Formula “ARI”**

Autori Smith i Senter objavili su ovu formulu 1967. godine, a naziv “ARI” je kratica za engleski naziv “Automated Readability Index”, što znači “automatizirani indeks čitkosti” i ukazuje na mogućnost računanja formule računalnim programima. Kao i formula “Coleman-Liau Index”, temelji se na broju znakova u riječima, a ne na broju slogova kao ranije opisane formule čitkosti. Isto tako, indeks formule označava stupanj školovanja koji bi čitatelj trebao imati kako bi mogao razumjeti pročitani tekst.

Formula “ARI” računa se na sljedeći način [115]:

$$\text{ARI} = 4,71 \times (\text{ch} / \text{w}) + 0,5 \times (\text{w} / \text{s}) - 21,43$$

gdje je ARI = “Automated Readability Index”; ch = ukupan broj znakova; w = ukupan broj riječi; s = ukupan broj rečenica.

#### **1.4.2.8. Formula “FORCAST”**

Autori Caylor, Sticht, Fox i Ford objavili su ovu formulu 1973. godine [118], kada su za potrebe američke vojske istraživali koja bi formula bila najprikladnija za testiranje stručnih materijala namijenjenih vojnicima, a da ju je ujedno jednostavno primijeniti bez dodatnog obučavanja osoblja koje bi formulu koristilo. Kao polazište su koristili tekstove koji su bili procijenjeni Fleschovom formulom čitkosti, a zatim su testirali vojnike testom Cloze napravljenom na osnovu tih tekstova. Prema dobivenim rezultatima testa Cloze s višestrukim odgovorima zatim su nanovo procijenili težinu tekstova, uz uvjet da je barem 50% ispitanika imalo rezultat testa 35% ili više. Od

ukupno 15 varijabli koje su istraživali, najveću korelaciju pokazao je broj jednosložnih riječi pa je on uvršten u formulu, a budući da dužina rečenice nije pridonijela pouzdanosti formule, ta je varijabla izostavljena, što je ujedno neobičnost formule čitkosti [90]. Formula FORCAST glasi:

$$\text{broj razreda} = 20 - (N + 10)$$

gdje je  $N$  = broj jednosložnih riječi na svakih 150 riječi.

Ova se formula pokazuje valjanom u rasponu od 5. do 12. razreda, a vrlo je popularna za kratke uzorke tekstova, tekstove na internetskim stranicama, tekstove različitih formulara i obrazaca. Američka vojska je za svoje materijale koji se koriste u zračnim snagama uvela ovu formulu kao svoj standard [90].

### **1.4.3. Formule čitkosti za neenglesko govorno područje**

#### **1.4.3.1. Formule SOL**

Formule nazvane “SOL” su ustvari modifikacije formule SMOG, napravljene za španjolski i francuski jezik. Sam je naziv dan u želji da se ponudi nešto pozitivno, za razliku od značenja formule SMOG, pa su autori smatrali da za te dvije mediteranske zemlje bolje odgovara naziv koji asocira na sunce [94]. Analizirali su prijevode istih tekstova ali različitih težina, ukupno 97 blokova od 30 rečenica za španjolski i engleski jezik te 67 blokova od 30 rečenica za francuski i engleski te francuski i španjolski jezik,



a dobivene indekse čitkosti prema formuli SMOG konvertirali su prema sljedećim jednadžbama kako bi izrazili varijacije među jezicima [94]:

- 1) formula za španjolski jezik u odnosu na engleski

$$\text{SOL šp.} = 1,95 + 2,23 \times E - 0,006 \times E^2$$

- 2) formula za francuski jezik u odnosu na engleski

$$\text{SOL fr.} = 5,51 + 0,92 \times E$$

- 3) formula za francuski jezik u odnosu na španjolski

$$\text{SOL fr.} = 5,03 + 0,52 \times S$$

- 4) formula za španjolski jezik u odnosu na francuski

$$\text{SOL šp.} = 15,21 - 0,96 \times F + 0,08 \times F^2$$

gdje je E = indeks čitkosti prema formuli SMOG za engleski jezik, S = indeks čitkosti prema formuli SMOG za španjolski jezik, a F = indeks čitkosti prema formuli SMOG za francuski jezik.

Autori također nude i obrnutu formulu, tj. za engleski jezik u odnosu na španjolski i francuski, kao i tablicu s gotovim vrijednostima konverzija za usporedbu i praktičnu primjenu [94].

Autori ovih formula u svom radu [94] zaključuju da je engleski jezik čitkiji od francuskog, a francuski čitkiji od španjolskog, očito na temelju dobivenih indeksa

čitkosti, ali u samom radu govore i kako im je polazište da su sva tri jezika jednako čitka i da varijacije u indeksima čitkosti ne znače da postoje razlike u težini čitanja, što nipošto nisu dosljedne tvrdnje.

#### **1.4.3.2. Formule za talijanski jezik**

Za talijanski jezik napravljene su također modifikacije postojećih formula za engleski jezik. Tako se formula autora Franchina i Vacca [119] temelji na Fleschovoj formuli primijenjenoj na bilingualnom talijansko-engleskom tekstu istog autora, a u literaturi se pojavljuje pod nazivom “Flesh-Vacca” [120] i računa se na sljedeći način:

$$206 - (0,65 \times S) - P$$

gdje je S = broj slogova na 100 riječi, a P = prosječni broj riječi u rečenici

Modifikacija formule Flesch-Kincaid prema tome za talijanski jezik glasi [121]:

$$11,8 \times S + 0,39 \times P - 15,59$$

Formulu GulpEase napravila je skupina talijanskih istraživača [122] te je nazvala prema početnim slovima svoje grupacije – “Gruppo Universitario Linguistico Pedagogico”, prema kojoj se ne računa broj slogova, već broj znakova pa formula glasi [121]:

$$89 - (lp/10) + (3 \times fr)$$

gdje je  $lp$  = broj znakova na 100 riječi / ukupni broj slova, a  $fr$  = ukupni broj rečenica x 100 / ukupni broj riječi

Indeks čitkosti se izražava na skali od 0 do 100, gdje je 0 najmanja čitkost a 100 najveća čitkost. Nadalje, daje se usporedba s indeksima dobivenim formulom Flesch-Kincaid pa indeksi 0-59 po formuli GulpEase odgovaraju vrijednostima 0-50 po formuli Flesch-Kincaid, indeksi 60-79 odgovaraju vrijednostima 50 do 80, te indeksi 80-100 odgovaraju vrijednostima 80-100 po formuli Flesch-Kincaid [120]. Osim toga, napominje se da isti indeks čitkosti predstavlja različitu težinu za različite stupnjeve školovanja pa ono što je lagano za visokoobrazovane, a standardno za osobe sa srednjim obrazovanjem, bit će izrazito teško i frustrirajuće za čitanje za osobe sa osnovnom školom [123].

#### **1.4.3.3. Formula za švedski jezik**

Formulu čitkosti za švedski jezik izradio je 1968. godine Carl-Hugo Björnsson [124], a temelji se na zbroju prosječne dužine rečenice i postotka dugih riječi, gdje se duga riječ definira kao riječ od sedam i više znakova [93]. Primijenjena je na velikom broju tekstova za djecu te časopisima na šest jezika, od švedskog, njemačkog, danskog, engleskog, finskog do francuskog [125]. Prikazano jednadžbom, formula Lix glasi [115]:

$$LIX = A/B + (C \times 100)/A$$

gdje je  $A$  = broj riječi,  $B$  = broj rečenica,  $C$  = broj dugih riječi (više od 6 znakova).

Indeksi čitkosti označavaju da vrijednost 20 znači jako lagan tekst, a 60 vrlo težak tekst [93], ali se mogu grupirati i detaljnije prikazati na sljedeći način [126]:

- < 24 vrlo lagano
- 25-34 lagano
- 35-44 osrednje
- 45-54 teško
- > 55 vrlo teško

#### **1.4.3.4. Formule za ostale jezike**

Osim navedenih, formule za ostale jezike neengleskog govornog područja razvili su sljedeći autori: za kineski, Yang 1971. godine; za danski, Jakobsen 1971. godine; za nizozemski, Douma 1960., Brouwer 1963., van Hauwermeiren 1972., Zondervan van Steen i Gunneweg 1976., Staphorsius i Krom 1985. godine; za francuski, Tharp 1939., Kandel i Moles 1958., De Landsheere 1963. i 1966., Henry 1973., Richaudeau 1973. godine; za njemački, Fucks 1955., Walters 1966., De Landsheere 1970., Briest 1974., Schwartz 1975., Nestler 1977., Dickes i Steiwer 1977., Bamberger i Vanecek 1982. i 1984.; za hebrejski, Nahshon 1957.; za hindi, Bhagoliwal 1961; za korejski, Park 1974.; za ruski, Rock 1970.; za španjolski, Spaulding 1951. i 1956., Fernandez Huerta 1959., Gutierrez 1972., Patterson 1972., Thonis 1976., Garcia 1977., Gilliam, Pena i Mountain 1980., Vari-Cartier 1981., Lopez Rodriguez 1981. i 1982., Rodriguez Dieguez 1983., Crawford 1984.; za švedski, Björnsson 1983., Platzack 1974.; za vijetnamski, Nguyen i Henkin 1985. godine [93].

Kod ovih navedenih formula mogu se izdvojiti neke zanimljivosti. Naprimjer, formula za danski jezik je ista kao Lix za švedski, a prihvatilo ju je Dansko povjerenstvo za formulu Lix [127].

Jedna od formula za nizozemski jezik [128] temelji se na generalizaciji samo pet tekstova, gdje je procjena da su u nizozemskom jeziku riječi i rečenice duže od engleskog za 10% pa modificiraju Fleschovu formulu tako da njena dva koeficijenta skraćuju za 11% te formula glasi:

$$206,84 - 0,77sw - 0,93ws$$

gdje je  $sw$  = broj slogova na 100 riječi, a  $ws$  = broj riječi u rečenici [93].

Jedna od formula za francuski jezik [129], koja se temelji na Fleschovoj formuli, uzima u obzir da su riječi u francuskom jeziku u prosjeku duže od riječi u engleskom jeziku pa koeficijent za dužinu riječi dijeli s 1,15 kako bi se dobila formula modificirana za francuski jezik [93]:

$$207 - 1,015ws - 0,736sw$$

gdje je  $ws$  = broj riječi u rečenici, a  $sw$  = broj slogova na 100 riječi.

Formulu za španjolski jezik, koja se temelji na Fleschovoj formuli, Huerta [130] je najprije isprobao u varijanti kakva se koristila za francuski jezik [129], ali budući da je njena primjena pokazala ograničene rezultate, prilagodio ju je na način da odgovara španjolskom jeziku te glasi:

$$206,84 - 0,60p - 1,02f$$

gdje je  $p$  = broj slogova na 100 riječi, a  $f$  = broj rečenica na 100 riječi [93].

Ostale navedene formule su vrlo složene te se temelje ili na cijelom nizu različitih varijabli, ili na popisima učestalih riječi, ili na grafikonima za očitavanje čitkosti, ali u svakom slučaju su modifikacije nužne zbog različitih struktura u različitim jezicima.

#### **1.4.4. Kritike i ograničenja formula čitkosti**

Koliko god su različite formule čitkosti pokazivale uspjeh tijekom desetljeća, uvijek su postojali autori koju su napadali njihovu upotrebu i zagovarali drugačiji pristup mjerenju težine teksta i razumijevanja. Kada se 60-tih godina 20. stoljeća u SAD-u pojavio pokret za promicanje jednostavnog govora, što je rezultiralo uvođenjem mjerenja težine teksta i prilagođavanje pisanih tekstova za javne i komercijalne svrhe i u zakonodavnom smislu, odmah je uslijedio napad na upotrebu formula čitkosti u te svrhe [131-137]. Međutim, još je 30-tih godina Ojemann [138] upozoravao da se formule ne smiju mehanički upotrebljavati, a takvo upozorenje se provlači kroz cjelokupno istraživanje čitkosti i razvoj formula čitkosti, a daju ga sami autori formula. Klare [139] je naglašavao da se indeksi čitkosti trebaju smatrati grubim vodičima, a ne vrlo preciznim i točnim vrijednostima, te kao takvi mogu itekako pomoći u brzom procjeni težine pisanih materijala [139].

Naravno da postoje brojni čimbenici koji utječu na čitanje i razumijevanje te da njihova analiza doprinosi našem boljem poznavanju ovih procesa. Ali, istraživanja su pokazala da je vrlo teško otkriti i mjeriti učinak različitih varijabli čitanja na razumijevanje, a formule čitkosti su se dokazale u pozitivnom svjetlu. Naprimjer, teoretičari kognitivnih znanosti analizirali su sadržaj, organizaciju i povezanost teksta te pokazali važnost ovih varijabli, ali nisu uspjeli ponuditi niti praktičnu ali objektivnu metodu za mjerenje niti

načine kako prilagoditi tekstove za različite razine čitatelja [90]. Kintsch [140] je na početku svog istraživačkog rada bio izrazito kritičan prema formulama čitkosti govoreći kako se one ne temelje na modernoj lingvističkoj teoriji da ne uzimaju u obzir interakciju čitatelja i teksta. Međutim, nakon samo četiri godine promijenio je svoje mišljenje [141] i priznao da formule čitkosti koreliraju s pojmovnim karakteristikama teksta te da su vokabular i dužina rečenice najjači prediktori težine teksta.

Može se reći da kritičari formula čitkosti [131,133-134,142-143] s pravom tvrde da formule čitkosti koriste samo “površinske” osobine teksta, a zanemaruju ostale, kao naprimjer sadržaj i organizaciju teksta. Međutim, pokazuje se da su upravo te površinske osobine, uza sva svoja ograničenja, najbolji prediktori težine teksta kad se uspoređi s rezultatima testova razumijevanja [98,132,141,144-152]. Također, kada se postojeći tekst revidira sa svrhom poboljšanja razumijevanja, ne smije se prepravljati kako bi samo zadovoljio formulu čitkosti, jer se tada formule čitkosti ustvari zloupotrebljavaju [90]. Puko skraćivanje riječi i rečenica neće povećati razumljivost teksta, ali pojednostavljivanje vokabulara ipak pozitivno utječe na razumijevanje [91], kao što je i prosječna dužina rečenice vrlo jasan pokazatelj težine teksta [145,153].

## 2. HIPOTEZE I CILJEVI ISTRAŽIVANJA

Hipoteze ove disertacije su sljedeće:

- hrvatski jezik je čitkiji od engleskog jezika te se stoga formule čitkosti koje su validirane za engleski jezik moraju prilagoditi za hrvatski jezik zbog lingvističkih varijacija u jeziku;
- kontrastivna analiza tekstova na engleskom i hrvatskom jeziku može dati uvid u one kvantitativne čimbenike koji su potrebni za modifikaciju formula čitkosti za hrvatski jezik.

Opći cilj predložene disertacije je izraditi model za izračunavanje čitkosti teksta koji će biti najprimjereniji za hrvatski jezik, a dobit će se kontrastivnom analizom tekstova na hrvatskom i engleskom jeziku, uz usporedbu s postojećim modelima na drugim jezicima.

Specifični ciljevi su sljedeći:

- izračunati čitkost tekstova na hrvatskom jeziku u usporedbi s čitkosti tekstova na engleskom jeziku;
- modificirati formule čitkosti za engleski jezik tako da budu primjerene za računanje čitkosti tekstova na hrvatskom jeziku;
- odrediti korelaciju formula čitkosti za hrvatski jezik;
- ponuditi najprimjereniju formulu čitkosti za tekstove na hrvatskom jeziku.



### **3. MATERIJALI I METODE**

#### **3.1. Materijal**

Predložena disertacija obuhvaća kontrastivnu analizu hrvatskog i engleskog jezika za one varijable koje su nužne za izradu formula čitkosti za hrvatski jezik, a koje se utvrđuju na temelju usporedbe s postojećim modelima na drugim jezicima odnosno na temelju rezultata kvantitativne analize jezičnih karakteristika prikupljenog korpusa prijevodnih tekstova.

Istraživanje se temelji na prijevodnim tekstovima različite očekivane težine, od znanstvenih članaka iz područja medicine, preko znanstvenopopularnih tekstova, općih tekstova za javnost, do jednostavnijih književnih tekstova. Uzorak tekstova obuhvaća tekstove na engleskom jeziku te njihove prijevode na hrvatskom jeziku, koji su javno dostupni te čiji su prijevodi nastali nakon 1995. godine. Svaka od ove četiri vrste tekstova zastupljena je blokovima (radovi, knjige) različitih autora odnosno tema, a svaki blok se analizira prema odabranim odlomcima, koji se sastoje od 30 rečenica s početka, sredine i kraja bloka, izostavljajući samu početnu i posljednju rečenicu, te naslove i podnaslove, kao što je uobičajeno i preporučeno u literaturi o istraživanju čitkosti. Konkretno, uzorak za analizu se sastoji od 15 odlomaka iz znanstvenih članaka objavljenih u časopisu JAMA (Journal of the American Medical Association), 18 odlomaka iz znanstvenopopularnih tekstova, 24 odlomka općih tekstova (reportaža o aktualnim zbivanjima) iz časopisa "SETimes" (Southeast European Times) [154], te 33 odlomka jednostavnijih književnih tekstova, te postojećih publiciranih prijevoda tih istih odlomaka na hrvatskom jeziku. Odlomci iz časopisa "SETimes" su relativno kratki pa su naizmjenično izostavljene početna odnosno posljednja rečenica u svakoj reportaži.

Dakle, analiza obuhvaća ukupno 90 odlomaka, što čini 2.700 rečenica, u tekstovima na engleskom jeziku, te njihov ekvivalent na hrvatskom jeziku. Popis svih odjeljaka nalazi se u Prilogu 1.

Kako bi se napravila adekvatna analiza odjeljaka, tekstovi su prilagođeni na sljedeći način: kratice su zamijenjene punim nazivima, brojevi su zamijenjeni slovima kako bi glasili da se pročitaju, složenice su napisane kao jedna ili više riječi ovisno o smislu cjeline, izostavljena je sva interpunkcija osim točke, a u hrvatskom jeziku su izostavljeni dijakritički znakovi. Rečenice koje se u tekstovima na engleskom jeziku ne pojavljuju u prijevodu na hrvatski jezik u omjeru 1 : 1 i obrnuto izostavljene su iz analize kako bi se ekvivalenti odlomaka pojavljivali u oba jezika u cjelini od točno 30 rečenica.

### **3.2. Metode**

Na navedenom uzorku tekstova na engleskom i hrvatskom jeziku primijenjene su formule čitkosti, koje su opisane u uvodnom dijelu disertacije. Primijenile su se one formule koje su primjerene za odraslu populaciju, za zdravstvenu komunikaciju te koje je moguće bez većih poteškoća primijeniti na hrvatski jezik. To konkretno uključuje sljedeće formule: SMOG, Flesch Reading Ease, Flesch-Kincaid, ARI i Lix. Navedene formule koristile su se u sljedećem obliku:

SMOG:  $3 + \sqrt{3^+}$  sloga [111]

Flesch Reading Ease (FRE):  $206,835 - 0,846 wl - 1,015 sl$  [57]

gdje je  $wl$  = dužina riječi izražena brojem slogova,

a sl = dužina rečenice izražena brojem riječi

Flesch-Kincaid:  $(0,39 \times ASL) + (11,8 \times ASW) - 15,59$  [90]

gdje je ASL = prosječna dužina rečenice,

a ASW = prosječni broj slogova po riječi

Automated Readability Index (ARI):  $4,71 \times (ch / w) + 0,5 \times (w / s) - 21,43$  [115]

gdje je ch = ukupan broj znakova; w = ukupan broj riječi;

s = ukupan broj rečenica.

Lix:  $A/B + (C \times 100)/A$  [115]

gdje je A = broj riječi, B = broj rečenica,

C = broj dugih riječi (više od 6 znakova).

Indeksi formula SMOG, Kincaid i ARI izražavaju godine školovanja potrebnih da se određeni tekst razumije, a indeksi formula FRE i Lix odgovaraju opisnoj skali težine teksta, kako je opisano u uvodnom dijelu ove radnje; za formulu FRE skala glasi: 90-100 vrlo lako, 80-90 lako, 70-80 donekle lako, 60-70 standardno, 50-60 donekle teško, 30-50 teško, 0-30 vrlo teško [106]; a za formulu Lix skala je sljedeća: < 24 vrlo lagano, 25-34 lagano, 35-44 osrednje, 45-54 teško, > 55 vrlo teško [126].

Za tekstove na hrvatskom jeziku dodatno su izračunate formule SMOG i Lix i u modificiranom obliku tj. SMOG gdje se višesložna riječ definira kao riječ od četiri i više slogova:  $3 + \sqrt{4^+}$  sloga; a Lix gdje se duga riječ definira kao riječ od više od 7 znakova odnosno slova.

Za računanje ukupnog broja riječi i broja znakova korištena je opcija “wordcount” iz računalnog programa za obradu teksta Word for Windows XP. Za računanje ukupnog

broja slogova i broja trosložnih riječi korišten je program za računanje ovih varijabli dostupan na Internetu [155], koji je izabran kao najpouzdaniji nakon što je uspoređen s rezultatima izvornih govornika za engleski i hrvatski jezik, koji su u probnom uzorku od deset odlomaka izračunali ove varijable. Rezultati izvornih govornika uspoređivani su s rezultatima računalnih programa za računanje ovih varijabli: Program 1 – opcija gramatike teksta računalnog programa za obradu teksta WordPerfect; Program 2 – program za izračun broja riječi i višesložnih riječi [155]. Za računanje broja riječi od više od šest znakova korišten je program analize teksta dostupan na Internetu [156], a računanje četverosložnih riječi u hrvatskim tekstovima ručno je napravio izvorni govornik hrvatskog jezika.

Za izračun samih formula i prosječnih vrijednosti dužine riječi i rečenica, kao i za grafički prikaz dijela rezultata koristio se računalni program Excel for Windows XP. Za izračun frekvencija, prosječnih i srednjih vrijednosti te raspona indeksa, kao i moguću konverziju indeksa između dva jezika, te za grafički prikaz ostatka rezultata primijenio se statistički program za analizu podataka SPSS.

## 4. REZULTATI

Rezultati istraživanja podijeljeni su u nekoliko preglednih cjelina: 1) rezultati analize izvornih govornika za odabir najadekvatnijeg računalnog programa za računanje ukupnog broja slogova i višesložnih riječi; 2) rezultati analize različitih varijabli nužnih za uvrštavanje u formule čitkosti dobivenih odabranim računalnim programima; 3) rezultati formula čitkosti za tekstove na engleskom i hrvatskom jeziku; 4) usporedba i konverzija indeksa za engleski jezik u indekse za hrvatski jezik po pojedinim formulama čitkosti.

### 4.1. Odabir računalnog programa

Tablica 3. Rezultati analize izvornog govornika engleskog jezika u usporedbi s dostupnim računalnim programima

Red.br. teksta	Program 1		Program 2		Izvorni govornik	
	broj slogova	broj višesložnih riječi	broj slogova	broj višesložnih riječi	broj slogova	broj višesložnih riječi
1.	295	17	276	13	278	13
2.	228	7	220	8	221	8
3.	330	24	367	22	366	22
4.	242	11	228	12	228	12
5.	472	17	452	12	449	12
6.	423	18	399	23	397	23
7.	465	22	445	24	440	23
8.	241	18	225	12	225	12
9.	251	12	235	8	234	8
10.	384	28	368	23	366	24

Probni uzorak od 10 tekstova na engleskom jeziku odnosi se na odlomke pod rednim brojem 13, 18, 22, 33, 27, 11, 20, 14, 16 i 6 iz Priloga 1. Računalni program 1 se odnosi na WordPerfect program za obradu teksta, koji sadrži gramatičku opciju računanja ukupnog broja slogova i višesložnih riječi. Računalni program 2 odnosi se na kalkulator za formulu SMOG, koji je dostupan na Internetu [155]. Izvorni govornik engleskog jezika je ručno računao ukupni broj slogova i višesložnih riječi. Pojam višesložne riječi odnosi se na riječi od tri i više slogova.

Iz tablice 3. jasno je vidljivo da se rezultati ručnog računanja izvornog govornika najbolje poklapaju sa računalnim programom 2, koji je odabran za računanje varijabli za cjelokupan uzorak tekstova na engleskom jeziku.

Tablica 4. Rezultati analize izvornog govornika hrvatskog jezika u usporedbi s dostupnim računalnim programima

Red.br. teksta	Program 1		Program 2		Izvorni govornik	
	broj slogova	broj višesložnih riječi	broj slogova	broj višesložnih riječi	broj slogova	broj višesložnih riječi
1.	381	55	383	58	401	65
2.	311	35	311	40	326	42
3.	499	70	481	72	521	78
4.	311	33	313	37	324	40
5.	662	88	635	87	679	97
6.	524	81	510	83	546	90
7.	545	74	516	72	561	81
8.	272	33	271	36	287	39
9.	336	52	330	48	344	52
10.	462	67	459	71	484	80

Probni uzorak od 10 tekstova na hrvatskom jeziku odnosi se na odlomke pod rednim brojem 13, 18, 22, 33, 27, 11, 20, 14, 16 i 6 iz Priloga 1, tako da predstavljaju prijevode tekstova iz uzorka koje je analizirao i izvorni govornik za engleski jezik. Računalni program 1 također se odnosi na WordPerfect program za obradu teksta, koji sadrži gramatičku opciju računanja ukupnog broja slogova i višesložnih riječi, a računalni program 2 također se odnosi na kalkulator za formulu SMOG, koji je dostupan na Internetu [155]. Izvorni govornik hrvatskog jezika je ručno računao ukupni broj slogova i višesložnih riječi. Pojam višesložne riječi odnosi se na riječi od tri i više slogova.

Iz tablice 4. vidljivo je da se rezultati ručnog računanja izvornog govornika za hrvatski jezik najbolje poklapaju sa računalnim programom 2, koji je zbog toga odabran za računanje varijabli za cjelokupan uzorak tekstova na hrvatskom jeziku.

## **4.2. Rezultati varijabli za formule čitkosti**

U tablicama 5. i 6. prikazani su rezultati primjene računalnih programa za računanje ukupnog broja riječi, ukupnog broja slogova, ukupnog broja znakova, višesložnih riječi definiranih kao riječi od tri i više slogova, zatim riječi s ukupno šest, sedam, osam i više slova u riječima. Prikazani rezultati za ukupan broj riječi od četiri i više slogova za hrvatski jezik rezultat su ručnog računanja izvornog govornika za hrvatski jezik budući da se računalni programi za računanje višesložnih riječi ograničavaju na riječi od tri i više slogova. Za hrvatski jezik dodatno su izračunate ove varijable ukupnog broja višesložnih riječi definiranih kao četiri i više sloga, kao i ukupan broj riječi od osam i više slova, zbog očekivane veće čitkosti hrvatskog jezika. U tablicama su također

prikazani i izračuni za prosječnu dužinu riječi u slogovima i znakovima, te prosječnu dužinu rečenice prema broju riječi. Navedene varijable su nužne za izračunavanje indeksa čitkosti prema različitim formulama čitkosti koje su korištene u ovom radu.

Tablica 5. Rezultati analize varijabli za formule čitkosti, za tekstove na engleskom jeziku

R.br.	Ukupni broj riječi	Ukupni broj slogova	Ukupni broj znakova	3+ sloga	6+ slova	7+ slova	Prosječna dužina riječi u slogovima	Prosječna dužina riječi u znakovima	Prosječna dužina rečenice
1	487	673	2120	25	128	73	1,3819	4,3532	16,2
2	401	540	1732	22	98	58	1,3466	4,3192	13,4
3	333	448	1433	22	77	53	1,3453	4,3033	11,1
4	451	677	2086	55	136	100	1,5011	4,6253	15,0
5	279	371	1110	20	62	41	1,3297	3,9785	9,3
6	259	368	1096	23	58	40	1,4208	4,2317	8,6
7	416	638	1920	50	139	82	1,5337	4,6154	13,9
8	494	748	2310	66	148	102	1,5142	4,6761	16,5
9	323	503	1482	54	100	74	1,5573	4,5882	10,8
10	466	748	2235	64	144	113	1,6052	4,7961	15,5
11	299	399	1215	23	65	35	1,3344	4,0635	10,0
12	252	349	1114	23	71	53	1,3849	4,4206	8,4
13	200	276	843	13	52	33	1,3800	4,2150	6,7
14	156	225	671	12	40	28	1,4423	4,3013	5,2
15	249	371	1155	30	72	57	1,4900	4,6386	8,3
16	183	235	710	8	28	23	1,2842	3,8798	6,1
17	220	281	888	8	54	29	1,2773	4,0364	7,3
18	163	220	678	8	40	21	1,3497	4,1595	5,4
19	590	776	2377	28	128	77	1,3153	4,0288	19,7
20	329	445	1421	24	78	49	1,3526	4,3191	11,0
21	404	522	1626	17	80	45	1,2921	4,0248	13,5
22	272	367	1127	22	65	38	1,3493	4,1434	9,1
23	308	406	1281	23	81	46	1,3182	4,1591	10,3
24	278	360	1182	13	62	43	1,2950	4,2518	9,3
25	442	640	2071	39	139	99	1,4480	4,6855	14,7
26	581	821	2643	58	169	120	1,4131	4,5491	19,4
27	360	452	1408	12	51	37	1,2556	3,9111	12,0
28	602	928	2842	72	197	159	1,5415	4,7209	20,1
29	632	895	2638	56	150	103	1,4161	4,1741	21,1
30	625	937	2886	81	193	138	1,4992	4,6176	20,8
31	356	498	1568	26	95	73	1,3989	4,4045	11,9
32	265	324	1020	12	49	26	1,2226	3,8491	8,8
33	174	228	681	12	33	18	1,3103	3,9138	5,8
34	530	840	2488	85	170	122	1,5849	4,6943	17,7
35	513	815	2459	73	179	131	1,5887	4,7934	17,1
36	716	1246	3705	137	274	211	1,7402	5,1746	23,9
37	528	720	2193	33	128	84	1,3636	4,1534	17,6
38	628	977	2953	82	209	144	1,5557	4,7022	20,9
39	659	1141	3312	135	240	192	1,7314	5,0258	22,0
40	859	1550	4496	193	373	280	1,8044	5,2340	28,6



41	620	1075	3258	126	264	184	1,7339	5,2548	20,7
42	605	1096	3222	130	257	204	1,8116	5,3256	20,2
43	538	937	2732	99	219	151	1,7416	5,0781	17,9
44	714	1342	3985	179	333	260	1,8796	5,5812	23,8
45	710	1283	3772	161	289	240	1,8070	5,3127	23,7
46	716	1200	3585	129	281	219	1,6760	5,0070	23,9
47	600	1010	3061	115	232	186	1,6833	5,1017	20,0
48	740	1355	3904	164	321	228	1,8311	5,2757	24,7
49	538	897	2757	100	207	151	1,6673	5,1245	17,9
50	729	1344	3891	183	312	251	1,8436	5,3374	24,3
51	717	1258	3668	154	272	209	1,7545	5,1158	23,9
52	624	1136	3316	147	244	206	1,8205	5,3141	20,8
53	911	1492	4429	156	312	211	1,6378	4,8617	30,4
54	666	1162	3439	129	260	206	1,7447	5,1637	22,2
55	660	1159	3427	122	261	199	1,7561	5,1924	22,0
56	871	1635	4727	212	358	280	1,8772	5,4271	29,0
57	797	1428	4208	180	321	253	1,7917	5,2798	26,6
58	736	1122	3352	79	201	147	1,5245	4,5543	24,5
59	649	1005	3067	89	205	149	1,5485	4,7257	21,6
60	600	983	2866	100	184	146	1,6383	4,7767	20,0
61	621	977	2873	89	190	142	1,5733	4,6264	20,7
62	634	1018	2985	100	200	152	1,6057	4,7082	21,1
63	625	1087	3135	124	217	166	1,7392	5,0160	20,8
64	519	762	2228	52	139	91	1,4682	4,2929	17,3
65	626	986	3010	77	223	160	1,5751	4,8083	20,9
66	600	876	2561	63	151	102	1,4600	4,2683	20,0
67	677	972	2937	62	175	122	1,4357	4,3383	22,6
68	576	891	2681	70	170	117	1,5469	4,6545	19,2
69	723	1109	3294	91	220	151	1,5339	4,5560	24,1
70	807	1353	4014	153	312	213	1,6766	4,9740	26,9
71	791	1340	3956	149	284	228	1,6941	5,0013	26,4
72	865	1506	4606	169	356	276	1,7410	5,3249	28,8
73	657	947	2904	72	177	122	1,4414	4,4201	21,9
74	834	1287	3885	121	250	189	1,5432	4,6583	27,8
75	656	1143	3382	125	255	198	1,7424	5,1555	21,9
76	683	1325	3812	180	315	254	1,9400	5,5813	22,8
77	715	1331	4002	164	329	268	1,8615	5,5972	23,8
78	762	1384	4158	175	343	269	1,8163	5,4567	25,4
79	681	1309	3726	160	310	256	1,9222	5,4714	22,7
80	680	1271	3643	155	284	239	1,8691	5,3574	22,7
81	924	1751	5001	221	409	329	1,8950	5,4123	30,8
82	678	1396	4029	185	331	280	2,0590	5,9425	22,6
83	796	1405	4341	147	343	260	1,7651	5,4535	26,5
84	650	1308	3782	177	319	262	2,0123	5,8185	21,7
85	769	1530	4352	212	334	287	1,9896	5,6593	25,6
86	715	1343	3992	153	318	267	1,8783	5,5832	23,8
87	864	1658	4811	215	383	332	1,9190	5,5683	28,8
88	634	1182	3566	143	293	254	1,8644	5,6246	21,1
89	764	1345	4072	134	299	254	1,7605	5,3298	25,5
90	611	1103	3419	123	274	233	1,8052	5,5957	20,4

Tablica 6. Rezultati analize varijabli za formule čitkosti, za tekstove na hrvatskom

jeziku

R. br.	Ukup. broj riječi	Ukup. broj slog.	Ukup. broj znak.	3+ sloga	4+ sloga	6+ slova	7+ slova	8+ slova	Prosječ. dužina riječi u slog..	Prosječ. dužina riječi u znak.	Prosječ. dužina rečen.
1	460	954	2307	133	66	184	119	83	2,0739	5,0152	15,3
2	369	696	1741	87	38	132	79	43	1,8862	4,7182	12,3
3	324	634	1529	89	40	115	81	53	1,9568	4,7191	10,8
4	389	814	2023	132	60	166	123	85	2,0925	5,2005	13,0
5	233	435	1062	53	29	77	56	34	1,8670	4,5579	7,8
6	219	459	1080	71	23	84	58	26	2,0959	4,9315	7,3
7	373	796	1923	130	55	169	118	70	2,1340	5,1555	12,4
8	444	927	2214	140	78	182	125	83	2,0878	4,9865	14,8
9	288	635	1517	111	52	125	101	78	2,2049	5,2674	9,6
10	390	871	2116	150	79	179	134	101	2,2333	5,4256	13,0
11	255	510	1208	83	27	100	71	40	2,0000	4,7373	8,5
12	216	423	1024	64	24	70	54	35	1,9583	4,7407	7,2
13	191	383	913	58	18	72	47	23	2,0052	4,7801	6,4
14	140	271	631	36	12	46	30	14	1,9357	4,5071	4,7
15	244	494	1170	75	36	91	70	47	2,0246	4,7951	8,1
16	164	330	776	48	29	58	45	33	2,0122	4,7317	5,5
17	220	439	1042	65	28	85	50	35	1,9955	4,7364	7,3
18	171	311	704	40	15	43	30	18	1,8187	4,1170	5,7
19	481	906	2195	118	50	156	106	62	1,8836	4,5634	16,0
20	270	516	1239	72	27	92	62	33	1,9111	4,5889	9,0
21	325	627	1508	82	31	102	72	48	1,9292	4,6400	10,8
22	240	482	1179	72	28	90	61	40	2,0083	4,9125	8,0
23	285	560	1327	92	44	106	81	56	1,9649	4,6561	9,5
24	250	499	1173	71	36	91	63	34	1,9960	4,6920	8,3
25	395	789	1973	117	48	158	110	71	1,9975	4,9949	13,2
26	551	1118	2657	190	65	227	158	102	2,0290	4,8221	18,4
27	344	635	1497	87	22	101	65	34	1,8459	4,3517	11,5
28	564	1256	3060	216	104	260	194	151	2,2270	5,4255	18,8
29	559	1094	2607	150	56	201	129	78	1,9571	4,6637	18,6
30	553	1183	2791	199	90	252	174	114	2,1392	5,0470	18,4
31	380	748	1771	110	46	142	96	60	1,9684	4,6605	12,7
32	245	426	985	55	15	59	37	21	1,7388	4,0204	8,2
33	168	313	695	37	11	41	28	14	1,8631	4,1369	5,6
34	457	965	2301	152	71	171	129	91	2,1116	5,0350	15,2
35	489	1093	2672	180	97	222	169	121	2,2352	5,4642	16,3
36	594	1441	3560	270	136	328	247	184	2,4259	5,9933	19,8
37	444	875	2112	119	50	158	105	67	1,9707	4,7568	14,8
38	529	1146	2838	182	79	234	169	121	2,1664	5,3648	17,6
39	597	1358	3443	239	132	312	251	184	2,2747	5,7672	19,9
40	810	1839	4668	327	185	434	319	241	2,2704	5,7630	27,0
41	547	1324	3271	239	121	294	222	178	2,4205	5,9799	18,2
42	560	1272	3226	220	121	300	225	157	2,2714	5,7607	18,7
43	483	1074	2636	176	86	239	160	112	2,2236	5,4576	16,1
44	643	1551	3841	286	171	360	287	217	2,4121	5,9736	21,4
45	649	1496	3649	262	162	327	250	184	2,3051	5,6225	21,6
46	638	1479	3772	263	147	342	258	197	2,3182	5,9122	21,3
47	506	1183	2975	222	110	291	204	152	2,3379	5,8794	16,9
48	683	1602	3996	295	174	370	283	225	2,3455	5,8507	22,8
49	486	1144	2813	208	107	251	206	152	2,3539	5,7881	16,2
50	642	1495	3774	254	153	350	273	210	2,3287	5,8785	21,4

51	650	1541	3860	274	159	342	270	208	2,3708	5,9385	21,7
52	571	1330	3243	232	121	283	226	157	2,3292	5,6795	19,0
53	862	1926	4653	335	159	409	307	222	2,2343	5,3979	28,7
54	555	1331	3340	241	125	312	227	177	2,3982	6,0180	18,5
55	596	1422	3536	262	152	321	260	191	2,3859	5,9329	19,9
56	817	1960	4900	372	190	455	375	284	2,3990	5,9976	27,2
57	680	1568	3963	273	151	365	285	200	2,3059	5,8279	22,7
58	683	1563	3763	285	133	329	261	184	2,2884	5,5095	22,8
59	541	1222	3034	209	116	258	197	142	2,2588	5,6081	18,0
60	529	1204	2872	213	108	256	187	133	2,2760	5,4291	17,6
61	546	1170	2837	182	87	245	189	120	2,1429	5,1960	18,2
62	572	1214	2976	200	99	244	198	136	2,1224	5,2028	19,1
63	522	1222	2907	222	123	265	216	154	2,3410	5,5690	17,4
64	426	881	2187	137	54	188	143	86	2,0681	5,1338	14,2
65	557	1185	2847	195	93	244	184	130	2,1275	5,1113	18,6
66	528	1100	2625	181	78	214	149	94	2,0833	4,9716	17,6
67	600	1275	3092	216	82	263	210	131	2,1250	5,1533	20,0
68	492	1079	2665	181	85	241	181	113	2,1931	5,4167	16,4
69	630	1385	3395	241	121	302	235	162	2,1984	5,3889	21,0
70	719	1640	3952	293	139	361	263	184	2,2809	5,4965	24,0
71	713	1695	4119	313	191	370	315	238	2,3773	5,7770	23,8
72	827	1982	5004	351	215	445	356	272	2,3966	6,0508	27,6
73	557	1142	2786	173	69	232	166	104	2,0503	5,0018	18,6
74	732	1589	3910	255	143	332	242	181	2,1708	5,3415	24,4
75	632	1434	3548	256	132	321	234	167	2,2690	5,6139	21,1
76	717	1805	4429	347	189	399	343	277	2,5174	6,1771	23,9
77	683	1681	4195	326	177	391	336	266	2,4612	6,1420	22,8
78	698	1701	4186	322	182	383	328	250	2,4370	5,9971	23,3
79	759	1803	4390	340	206	415	338	245	2,3755	5,7839	25,3
80	714	1653	4074	298	175	364	306	212	2,3151	5,7059	23,8
81	941	2223	5530	421	224	524	411	315	2,3624	5,8767	31,4
82	686	1854	4387	352	220	395	341	271	2,7026	6,3950	22,9
83	801	2027	4781	400	207	408	347	291	2,5306	5,9688	26,7
84	643	1722	4055	338	222	362	311	244	2,6781	6,3064	21,4
85	642	1713	4152	344	223	399	342	260	2,6682	6,4673	21,4
86	639	1677	3999	340	188	382	300	239	2,6244	6,2582	21,3
87	727	1934	4695	394	238	450	374	292	2,6602	6,4580	24,2
88	597	1604	3915	310	211	366	319	238	2,6868	6,5578	19,9
89	716	1805	4376	330	233	377	336	275	2,5209	6,1117	23,9
90	576	1556	3766	305	224	345	307	247	2,7014	6,5382	19,2

### 4.3. Rezultati formula čitkosti

U tablicama 7. i 8. prikazani su rezultati izračuna formula čitkosti, posebno za engleski i za hrvatski jezik. Formule čitkosti za koje su izračunati i prikazani rezultati pokrivaju najčešće korištene formule čitkosti, ručnu i računalnu verziju računanja indeksa čitkosti, te različite modele računanja indeksa čitkosti.

Tablica 7. Rezultati formula čitkosti, za tekstove na engleskom jeziku

R.br.	SMOG	FRE	Kincaid	ARI	LIX
1	8	73.4	7.0	7.2	31.2
2	8	79.3	5.5	5.6	27.8
3	8	81.8	4.6	4.4	27.0
4	10	64.6	8.0	7.9	37.2
5	7	84.9	3.7	2.0	24.0
6	8	77.9	4.5	2.8	24.1
7	10	63.0	7.9	7.2	33.6
8	11	62.0	8.7	8.8	37.1
9	10	64.2	7.0	5.6	33.7
10	11	55.3	9.4	8.9	39.8
11	8	83.8	4.0	2.7	21.7
12	8	81.1	4.0	3.6	29.4
13	7	83.3	3.3	1.8	23.2
14	6	79.5	3.5	1.4	23.1
15	8	72.4	5.2	4.6	31.2
16	6	92.0	1.9	-0.1	18.7
17	6	91.3	2.3	1.2	20.5
18	6	87.1	2.5	0.9	18.3
19	8	75.6	7.6	7.4	32.7
20	8	81.3	4.6	4.4	25.9
21	7	83.9	4.9	4.3	24.6
22	8	83.5	3.9	2.6	23.0
23	8	84.9	4.0	3.3	25.2
24	7	87.9	3.3	3.2	24.7
25	9	69.4	7.2	8.0	37.1
26	11	67.6	8.6	9.7	40.0
27	6	88.4	3.9	3.0	22.3
28	11	56.1	10.4	10.8	46.5
29	10	65.6	9.3	8.8	37.4
30	12	58.9	10.2	10.7	42.9
31	8	76.4	5.5	5.2	32.4
32	6	94.4	2.3	1.1	18.6
33	6	90.1	2.1	-0.1	16.1
34	12	54.8	10.0	9.5	40.7
35	12	55.1	9.8	9.7	42.6
36	15	35.4	14.3	14.9	53.3
37	9	73.6	7.4	6.9	33.5
38	12	54.0	10.9	11.2	43.9
39	15	38.1	13.4	13.2	51.1
40	17	25.1	16.9	17.5	61.2
41	14	39.2	12.9	13.7	50.3
42	14	33.1	13.7	13.7	53.9
43	13	41.3	12.0	11.5	46.0
44	16	23.7	15.9	16.8	60.2
45	16	29.9	15.0	15.4	57.5
46	14	40.8	13.5	14.1	54.5
47	14	44.1	12.1	12.6	51.0
48	16	26.9	15.6	15.8	55.5
49	13	47.6	11.1	11.7	46.0
50	17	26.2	15.6	15.9	58.7

51	15	34.1	14.4	14.6	53.0
52	15	31.7	14.0	14.0	53.8
53	15	37.5	15.6	16.7	53.5
54	14	36.7	13.7	14.0	53.1
55	14	35.9	13.7	14.0	52.2
56	18	18.6	17.9	18.6	61.2
57	16	28.3	15.9	16.7	58.3
58	12	53.0	12.0	12.3	44.5
59	12	53.9	11.1	11.6	44.6
60	13	47.9	11.5	11.1	44.3
61	12	52.7	11.0	10.7	43.6
62	13	49.5	11.6	11.3	45.1
63	14	38.6	13.1	12.6	47.4
64	10	65.1	8.5	7.4	34.8
65	12	52.4	11.1	11.7	46.4
66	11	63.0	9.4	8.7	37.0
67	11	62.5	10.2	10.3	40.6
68	11	56.5	10.2	10.1	39.5
69	13	52.6	11.9	12.1	45.0
70	15	37.7	14.7	15.4	53.3
71	15	36.8	14.7	15.3	55.2
72	16	30.3	16.2	18.1	60.7
73	11	62.7	10.0	10.3	40.5
74	14	48.1	13.5	14.4	50.5
75	14	37.2	13.5	13.8	52.0
76	16	19.6	16.2	16.2	60.0
77	16	25.2	15.7	16.8	61.3
78	16	27.4	15.7	17.0	60.7
79	16	21.2	15.9	15.7	60.3
80	15	25.7	15.3	15.1	57.8
81	18	15.3	18.8	19.5	66.4
82	17	9.7	17.5	17.9	63.9
83	15	30.6	15.6	17.5	59.2
84	16	14.6	16.6	16.8	62.0
85	18	12.5	17.9	18.0	63.0
86	15	23.7	15.9	16.8	61.2
87	18	15.3	18.3	19.2	67.2
88	15	27.7	14.7	15.6	61.2
89	15	32.1	15.1	16.4	58.7
90	14	33.4	13.7	15.1	58.5

Iz tablice 7. vidljivo je da indeksi čitkosti pokazuju očekivanu veću čitkost jednostavnijih književnih tekstova, a manju čitkost složenijih, popularno-znanstvenih i znanstvenih tekstova. Konkretno vrijednosti po pojedinim formulama se razlikuju budući da izražavaju s jedne strane različite pojmove, a s druge strane očekivana minimalna odstupanja po različitim formulama. Tako, naprimjer, formule SMOG, Kincaid i ARI izražavaju broj godina školovanja, FRE se mjeri na skali od 0-100, gdje je 100 najveća čitkost odnosno najjednostavniji način izražavanja, a vrijednosti za

formulu Lix također izražavaju skalu, gdje su indeksi ispod 25 jako lagan, a iznad 55 jako težak tekst za razumijevanje.

Tablica 8. Rezultati formula čitkosti, za tekstove na hrvatskom jeziku

R.br.	SMOG (3+sloga)	SMOG (4+sloga)	FRE	Kincaid	ARI	LIX (7+slova)	LIX (8+slova)
1	15	11	15.8	14.9	9.9	41.2	33.4
2	12	9	34.8	11.5	6.9	33.7	24.0
3	12	9	30.3	11.7	6.2	35.8	27.2
4	14	11	16.6	14.2	9.5	44.6	34.8
5	10	8	41.0	9.5	3.9	31.8	22.4
6	11	8	22.1	12.0	5.4	33.8	19.2
7	14	10	13.7	14.4	9.1	44.1	31.2
8	15	12	15.2	14.8	9.5	43.0	33.5
9	14	10	10.6	14.2	8.2	44.7	36.7
10	15	12	4.7	15.8	10.6	47.4	38.9
11	12	8	29.0	11.3	5.1	36.3	24.2
12	11	8	33.9	10.3	4.5	32.2	23.4
13	11	7	30.7	10.6	4.3	31.0	18.4
14	9	6	38.3	9.1	2.1	26.1	14.7
15	12	9	27.3	11.5	5.2	36.8	27.4
16	10	8	31.1	10.3	3.6	32.9	25.6
17	11	8	30.6	10.8	4.5	30.1	23.2
18	9	7	47.2	8.1	0.8	23.2	16.2
19	14	10	31.2	12.9	8.1	38.1	28.9
20	11	8	36.0	10.5	4.7	32.0	21.2
21	12	9	32.6	11.4	5.8	33.0	25.6
22	11	8	28.8	11.2	5.7	33.4	24.7
23	13	10	31.0	11.3	5.3	37.9	29.1
24	11	9	29.5	11.2	4.8	33.5	21.9
25	14	10	24.5	13.1	8.7	41.0	31.1
26	17	11	16.5	15.5	10.5	47.0	36.9
27	12	8	39.0	10.7	4.8	30.4	21.4
28	18	13	-0.6	18.0	13.5	53.2	45.6
29	15	10	22.4	14.8	9.9	41.7	32.6
30	17	12	7.1	16.8	11.6	49.9	39.0
31	13	10	27.4	12.6	6.9	37.9	28.5
32	10	7	51.4	8.1	1.6	23.3	16.7
33	9	6	43.5	8.6	0.9	22.3	13.9
34	15	11	12.7	15.3	9.9	43.5	35.1
35	16	13	1.2	17.1	12.5	50.9	41.0
36	19	15	-18.5	20.8	16.7	61.4	50.8
37	14	10	25.1	13.4	8.4	38.4	29.9
38	16	12	5.7	16.8	12.7	49.6	40.5
39	18	14	-5.8	19.0	15.7	61.9	50.7
40	21	17	-12.6	21.7	19.2	66.4	56.8
41	18	14	-16.4	20.1	15.9	58.8	50.8
42	18	14	-4.3	18.5	15.0	58.8	46.7
43	16	12	2.4	16.9	12.3	49.2	39.3
44	20	16	-19.0	21.2	17.4	66.1	55.2

45	19	16	-10.1	20.0	15.9	60.2	50.0
46	19	15	-10.9	20.1	17.0	61.7	52.1
47	18	13	-8.1	18.6	14.7	57.2	46.9
48	20	16	-14.7	21.0	17.5	64.2	55.7
49	17	13	-8.7	18.5	13.9	58.6	47.5
50	19	15	-11.9	20.2	17.0	63.9	54.1
51	20	16	-15.7	20.8	17.4	63.2	53.7
52	18	14	-9.5	19.3	14.8	58.6	46.5
53	21	16	-11.4	22.0	18.4	64.3	54.5
54	19	14	-14.8	19.9	16.2	59.4	50.4
55	19	15	-15.2	20.3	16.4	63.5	51.9
56	22	17	-23.8	23.3	20.4	73.1	62.0
57	20	15	-11.2	20.5	17.4	64.6	52.1
58	20	15	-9.9	20.3	15.9	61.0	49.7
59	17	14	-2.6	18.1	14.0	54.4	44.3
60	18	13	-3.6	18.1	13.0	53.0	42.8
61	16	12	7.1	16.8	12.1	52.8	40.2
62	17	13	7.9	16.9	12.6	53.7	42.8
63	18	14	-8.9	18.8	13.5	58.8	46.9
64	15	10	17.5	14.4	9.9	47.8	34.4
65	17	13	8.0	16.8	11.9	51.6	41.9
66	16	12	12.7	15.9	10.8	45.8	35.4
67	18	12	6.8	17.3	12.8	55.0	41.8
68	16	12	4.7	16.7	12.3	53.2	39.4
69	19	14	-0.5	18.5	14.5	58.3	46.7
70	20	15	-10.5	20.7	16.4	60.5	49.6
71	21	17	-18.4	21.7	17.7	67.9	57.1
72	22	18	-23.9	23.4	20.9	70.6	60.5
73	16	11	14.5	15.8	11.4	48.4	37.2
74	19	15	-1.6	19.5	15.9	57.5	49.1
75	19	14	-6.5	19.4	15.5	58.1	47.5
76	22	17	-30.4	23.4	19.6	71.7	62.5
77	21	16	-24.5	22.3	18.9	72.0	61.7
78	21	16	-22.9	22.2	18.4	70.3	59.1
79	21	17	-19.8	22.3	18.5	69.8	57.6
80	20	16	-13.2	21.0	17.3	66.7	53.5
81	24	18	-24.9	24.5	21.9	75.0	64.8
82	22	18	-45.0	25.2	20.1	72.6	62.4
83	23	17	-34.4	24.7	20.0	70.0	63.0
84	21	18	-41.5	24.4	19.0	69.8	59.4
85	22	18	-40.6	24.2	19.7	74.7	61.9
86	21	17	-36.8	23.7	18.7	68.2	58.7
87	23	18	-42.8	25.3	21.1	75.7	64.4
88	21	18	-40.7	23.9	19.4	73.3	59.8
89	21	18	-30.7	23.5	19.3	70.8	62.3
90	20	18	-41.2	23.8	19.0	72.5	62.1

Kao i u tablici 7., i tablica 8. pokazuje da indeksi čitkosti pokazuju očekivanu veću čitkost jednostavnijih književnih tekstova, a manju čitkost složenijih, popularno-znanstvenih i znanstvenih tekstova. Isto dako se i konkretne vrijednosti po pojedinim formulama razlikuju budući da izražavaju s jedne strane različite pojmove, a s druge

strane očekivana minimalna odstupanja po različitim formulama. U usporedbi s tekstovima na engleskom jeziku iz tablice 7., vidljivo je da su prijevodi tih tekstova na hrvatskom jeziku po svojim indeksima čitkosti usporedivi s indeksima dobivenima za engleski jezik po pojedinim formulama, što znači da je konverzija indeksa čitkosti moguća te su način i rezultati konverzije prikazani u daljnjem tekstu rezultata.

#### **4.4. Usporedba i konverzija indeksa čitkosti**

U sljedećim tablicama prikazana je usporedba indeksa čitkosti po pojedinim formulama i za pojedine indekse čitkosti kako bi se omogućila konverzija indeksa za engleski jezik u indekse za hrvatski jezik odnosno kako bi se omogućila modifikacija pojedine formule za engleski jezik u odgovarajuću formulu za hrvatski jezik. Usporedba je prikazana najprije za tri formule čiji rezultat označava godine školovanja koje su potrebne da bi čitatelj bez poteškoća pročitao odnosno razumio određeni tekst, a predstavljaju tri različita modela računanja čitkosti. Te tri formule uključuju SMOG, Kincaid i ARI, jer formula SMOG za varijablu uzima samo ukupni broj višesložnih riječi, dok Kincaid uzima u obzir dužinu rečenice i prosječni broj slogova, a ARI uzima u obzir dužinu rečenice i dužinu riječi mjerenu brojem znakova. Dok se formule Kincaid i ARI računaju najlakše i najbrže upotrebom računala, formula SMOG je poznata po ručnom računanju, naročito kad je u pitanju hrvatski jezik, gdje se pojam višesložne riječi može definirati i kao riječi od četiri i više slogova pa je računanje višesložnih riječi iznimno brzo. Rezultati ovih formula prikazani su u tablicama 9.-12. i njima pripadajućim grafikonima. Nakon toga je prikazana konverzija za dvije formule koje čitkost izražavaju opisno na skali od najjednostavnijeg do najsloženijeg načina izražavanja odnosno od najlakšeg do najtežeg teksta za razumijevanje. To su formula FRE, koja je



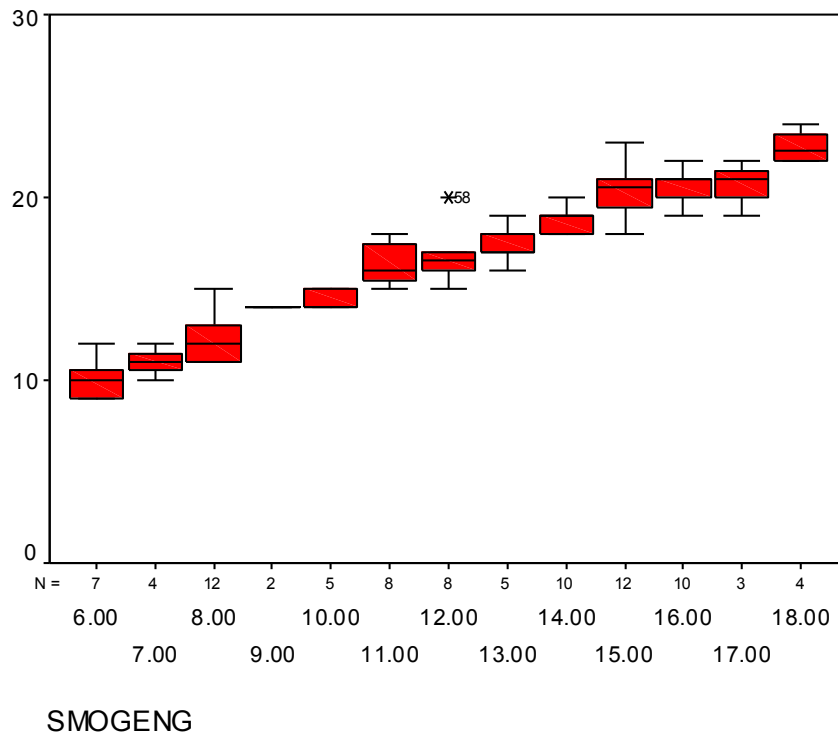
vrlo popularna, nalazi se u računalnim programima za obradu teksta i temelji se na broju slogova u riječima i dužini rečenice, a zatim i formula Lix, koja je napravljena prvenstveno za švedski jezik i temelji se na dužini rečenice i broju riječi dužih od šest slova. Rezultati za ove dvije formule prikazani su kroz ponuđene modifikacije formula.

Tablica 9. Usporedba indeksa čitkosti tekstova na engleskom i hrvatskom jeziku, prema formuli SMOG, na temelju višesložnih riječi u hrvatskom jeziku od tri i više sloga

SMOG engleski	SMOG hrvatski			
	n	raspon	prosječna vrijednost	srednja vrijednost
6	7	9-12	10	10
7	4	10-12	11	11
8	12	11-15	12,3	12
9	2	14	14	14
10	5	14-15	14,4	14
11	8	15-18	16,4	16
12	8	15-20	16,8	16,5
13	5	16-19	17,4	17
14	10	18-20	18,7	19
15	12	18-23	20,3	20,5
16	10	19-22	20,7	21
17	3	19-22	20,7	21
18	4	22-24	22,8	22,5

Tablica 9. prikazuje kako indeksi čitkosti za tekstove na engleskom i na hrvatskom jeziku imaju slične uzlazne trendove za povećane razine težine teksta, što je izraženije kroz prosječne vrijednosti.

Grafički, trend indeksa čitkosti na engleskom i hrvatskom jeziku, može se prikazati kao na slici 1, gdje se uočava linearni porast indeksa.



Slika 1. Trend i usporedba indeksa čitkosti po formuli SMOG za tekstove na engleskom i hrvatskom jeziku, prema višesložnim riječima od tri i više sloga

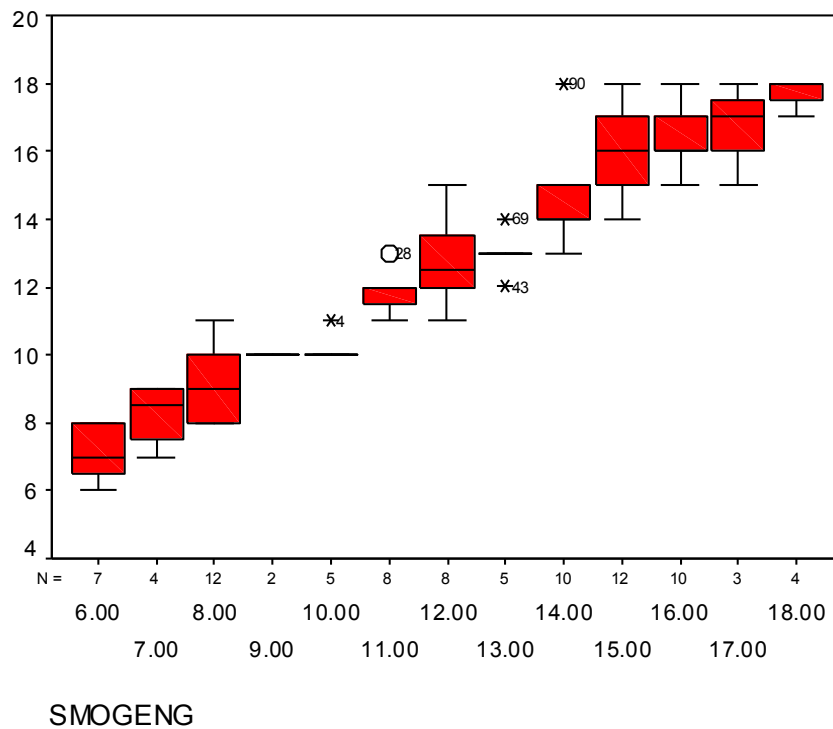
Tablica 10. Usporedba indeksa čitkosti tekstova na engleskom i hrvatskom jeziku, prema formuli SMOG, na temelju višesložnih riječi u hrvatskom jeziku od četiri i više slogova

SMOG engleski	SMOG hrvatski			
	n	raspon	prosječna vrijednost	srednja vrijednost
6	7	6-8	7,1	7

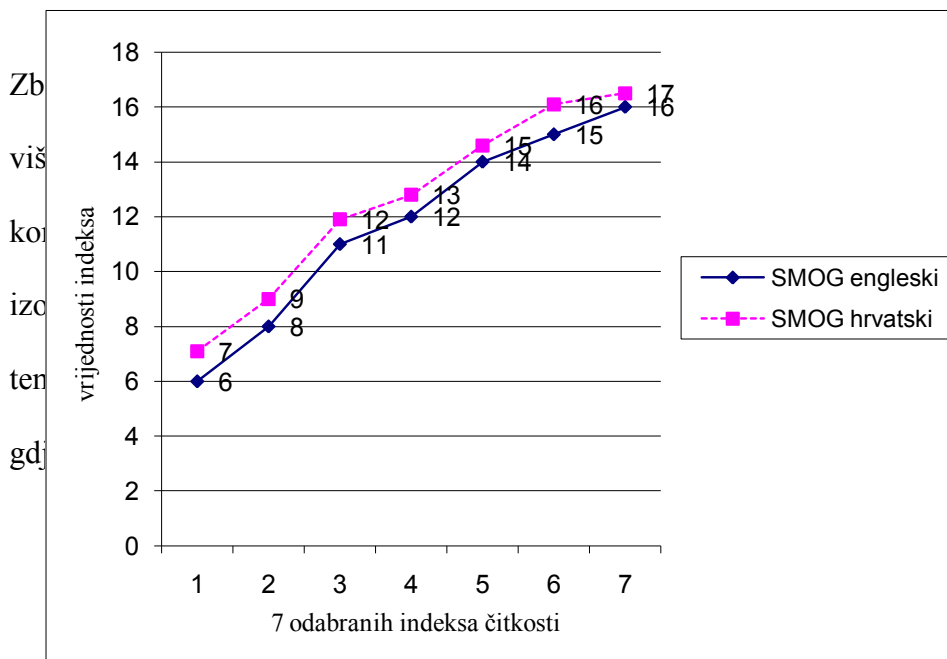
7	4	7-9	8,3	8,5
8	12	8-11	9	9
9	2	10	10	10
10	5	10-11	10,2	10
11	8	11-13	11,9	12
12	8	11-15	12,8	12,5
13	5	12-14	13	13
14	10	13-18	14,6	14
15	12	14-18	16,1	16
16	10	15-18	16,5	16
17	3	15-18	16,7	17
18	4	17-18	17,8	18

Iz tablice 10. vidljivo je kako indeksi čitkosti za tekstove na engleskom i na hrvatskom jeziku imaju slične uzlazne trendove za povećane razine težine teksta i kada se uzme u obzir pojam višesložnosti definiran kao riječi od četiri i više slogova.

Grafički se trend indeksa čitkosti na engleskom i hrvatskom jeziku može vidjeti na slici 2.



Slika 2. Trend i usporedba indeksa čitkosti po formuli SMOG za tekstove na engleskom i hrvatskom jeziku, prema višesložnim riječima od četiri i više slogova



eziku kada se  
o polazište za  
zik. Kada se  
eziku koji se  
ao na slici 3.,  
a.

Slika 3. Odstupanje vrijednosti indeksa čitkosti za hrvatski jezik po formuli SMOG prema višesložnim riječima od četiri i više slogova

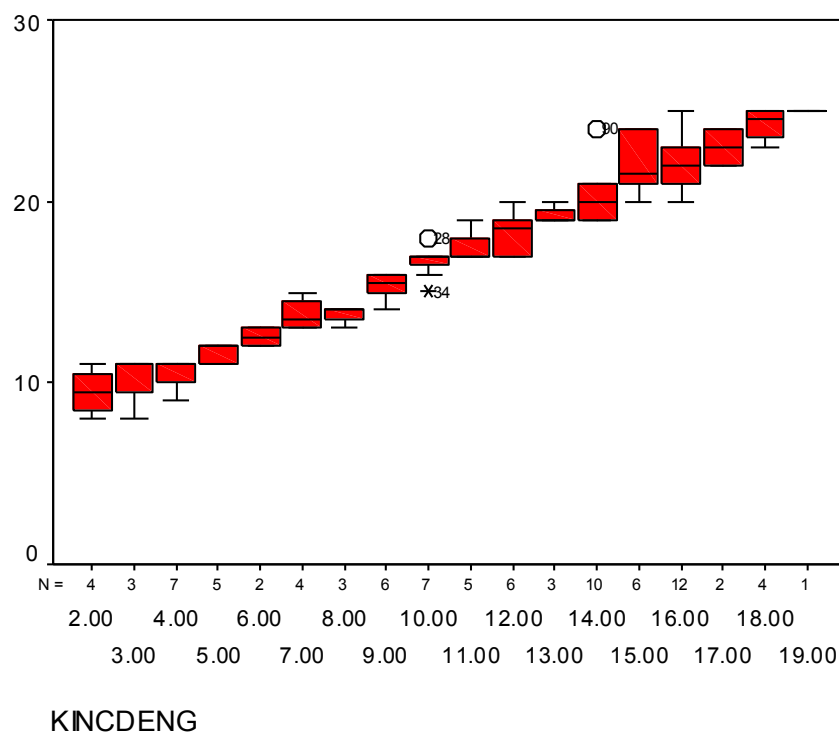
Na temelju dobivenih razlika, formulu za engleski jezik, koja u pojednostavljenom obliku glasi:  $SMOG = 3 + \sqrt{3^+}$  sloga, možemo modificirati za hrvatski jezik tako da glasi:  $SMOG \text{ (hrvatski)} = 2 + \sqrt{4^+}$  sloga, kako bi odražavala isti stupanj školovanja kao i formula na engleskom jeziku.

Tablica 11. Usporedba indeksa čitkosti tekstova na engleskom za hrvatskom jeziku, prema formuli Kincaid

Kincaid engleski	Kincaid hrvatski			
	n	raspon	prosječna vrijednost	srednja vrijednost
2	4	8-11	9,5	9,5
3	3	8-11	10	11
4	7	9-11	10,4	11
5	5	11-12	11,6	12
6	2	12-13	12,5	12,5
7	4	13-15	13,8	13,5
8	3	13-14	13,7	14
9	6	14-16	15,3	15,5
10	7	15-18	16,7	17
11	5	17-19	17,6	17
12	6	17-20	18,3	18,5
13	3	19-20	19,3	19
14	10	19-24	20,3	20
15	6	20-24	22	21,5
16	12	20-25	22,2	22
17	2	22-24	23	23
18	4	23-25	24,3	24,5
19	1	24,5	24,5	24,5

Iz tablice 11. vidljivo je kako sličan uzlazni trend indeksa čitkosti na engleskom jeziku možemo uočiti u indeksima čitkosti za hrvatski jezik, što se pokazalo i formulom SMOG. Iako formula Kincaid i SMOG ne pokazuju identične indekse čitkosti, sličan uzlazni trend opaža se i za svaki jezik pojedinačno, što odgovara različitim razinama težine teksta.

Grafički se trend indeksa čitkosti po formuli Kincaid može prikazati kao na slici 4.



Slika 4. Trend i usporedba indeksa čitkosti po formuli Kincaid za tekstove na engleskom i hrvatskom jeziku

Budući da sličan uzlazni trend postoji, a kako se vidi iz tablice 11. raspon indeksa je vrlo širok te u uzorku ne postoji velik broj tekstova koji predstavljaju svaki indeks, pokušaj modifikacije formule se temelji na prosječnoj razlici vrijednosti između indeksa za engleski i hrvatski jezik. Prosječna razlika vrijednosti indeksa prikazanih u tablicama 7. i 8. iznosi 6,5 odnosno za toliko su u prosjeku veće vrijednosti u hrvatskom jeziku pa

se predlaže da se za hrvatski jezik koristi postojeća formula napravljena za engleski jezik uz uvjet da se od rezultata oduzme koeficijent 6,5 i time izrazi razlika između ova dva jezika. Dakle, formula Kincaid za engleski jezik, koja glasi:

$$\text{broj razreda} = (0,39 \times \text{ASL}) + (11,8 \times \text{ASW}) - 15,59$$

odnosno pojednostavljena verzija koja glasi:

$$\text{broj razreda} = (0,4 \text{ ASL}) + (12 \text{ ASW}) - 15$$

za tekstove na hrvatskom jeziku glasila bi:

$$\text{broj razreda} = (0,39 \times \text{ASL}) + (11,8 \times \text{ASW}) - 22$$

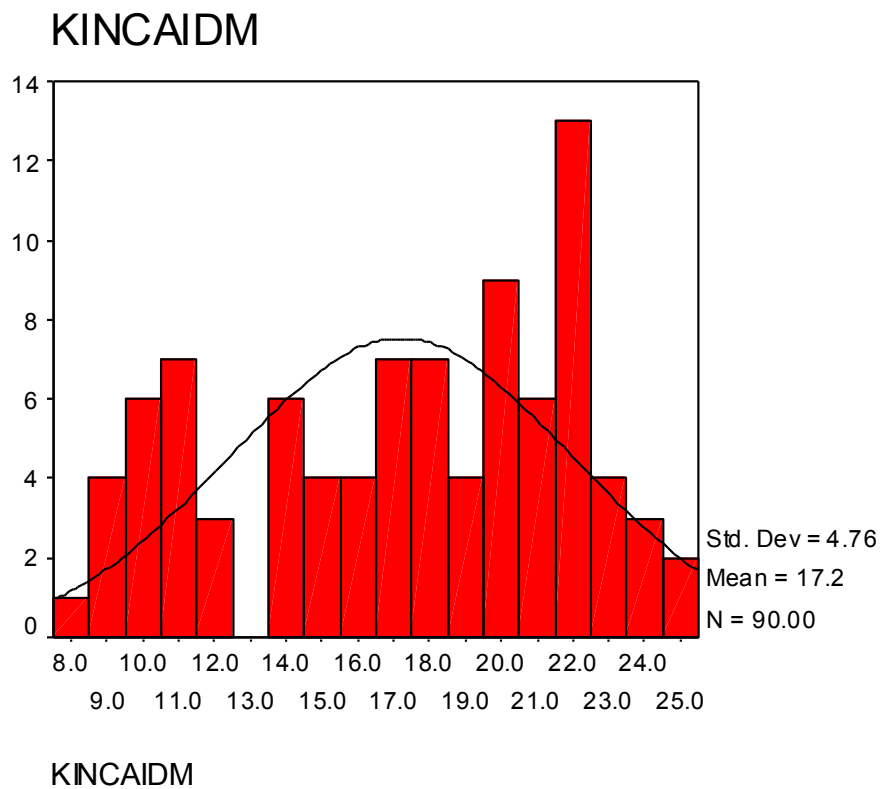
odnosno pojednostavljena verzija glasila bi:

$$\text{broj razreda} = (0,4 \text{ ASL}) + (12 \text{ ASW}) - 22$$

gdje je ASL = prosječna dužina rečenice, a ASW = prosječni broj slogova po riječi.

Opravdanost modifikacije postojeće formule za hrvatski jezik na ovaj način može se vidjeti iz slike 5., koja pokazuje pravilnu krivulju frekvencija odstupanja po pojedinim indeksima čitkosti analiziranih tekstova.





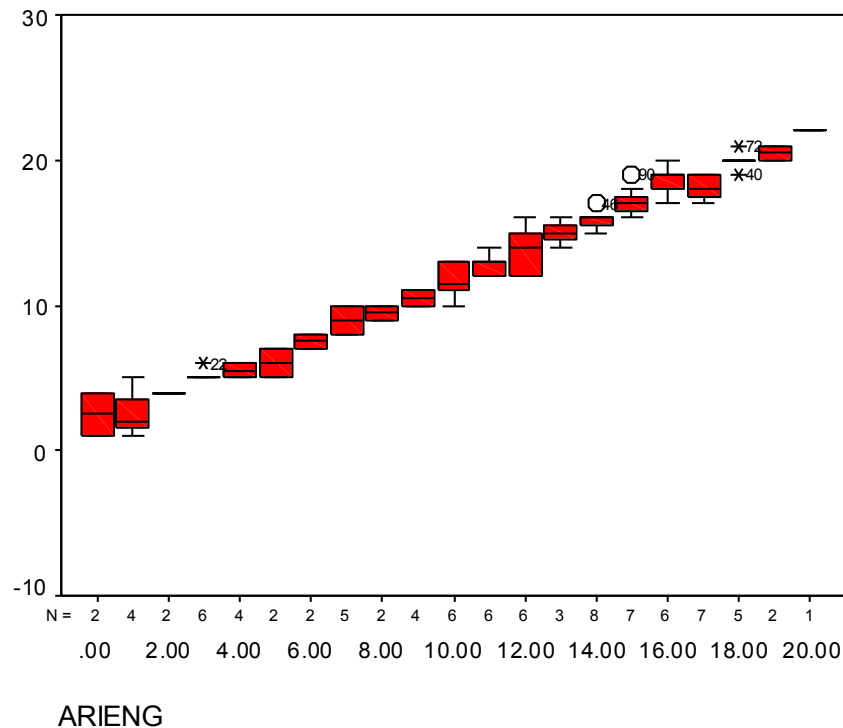
Slika 5. Frekvencije odstupanja modificirane formule Kincaid po pojedinim tekstovima na hrvatskom jeziku

Tablica 12. Usporedba indeksa čitkosti tekstova na engleskom i hrvatskom jeziku, prema formuli ARI

ARI engleski	ARI hrvatski			
	n	raspon	prosječna vrijednost	srednja vrijednost
0	2	1-4	2,5	2,5
1	4	1-5	2,5	2
2	2	4	4	4
3	6	5-6	5,2	5
4	4	5-6	5,5	5,5
5	2	5-7	6	6
6	2	7-8	7,5	7,5
7	5	8-10	9	9
8	2	9-10	9,5	9,5
9	4	10-11	10,5	10,5
10	6	10-13	11,7	11,5
11	6	12-14	12,8	13
12	6	12-16	13,8	14
13	3	14-16	15	15
14	8	15-17	15,9	16
15	7	16-19	17,1	17
16	6	17-20	18,7	19
17	7	17-19	16,1	18
18	5	19-21	20	20
19	2	20-21	20,5	20,5
20	1	22	22	22

Iz tablice 12. je vidljivo kako postoji sličan uzlazni trend za indekse čitkosti na engleskom i na hrvatskom jeziku, a taj uzlazni trend se poklapa s indeksima čitkosti za iste tekstove prema ostalim formulama čitkosti, iako sami rezultati formula nisu identični.

Grafički se trend indeksa čitkosti za engleski i hrvatski jezik prema formuli ARI može prikazati kao na slici 6.



Slika 6. Trend i usporedba indeksa čitkosti po formuli ARI za tekstove na engleskom i hrvatskom jeziku

Kao i kod formule Kincaid, budući da sličan uzlazni trend postoji, a kako se vidi iz tablice 12. raspon indeksa je vrlo širok te u uzorku ne postoji velik broj tekstova koji predstavljaju svaki indeks, pokušaj modifikacije formule se temelji na prosječnoj razlici vrijednosti između indeksa za engleski i hrvatski jezik. Prosječna razlika vrijednosti indeksa prikazanih u tablicama 7. i 8. iznosi 1,8 odnosno za toliko su vrijednosti veće u hrvatskom jeziku pa se predlaže da se za hrvatski jezik koristi postojeća formula napravljena za engleski jezik uz uvjet da se od rezultata oduzme koeficijent 1,8 i time izrazi razlika između ova dva jezika. Dakle, formula ARI za engleski jezik, koja glasi:

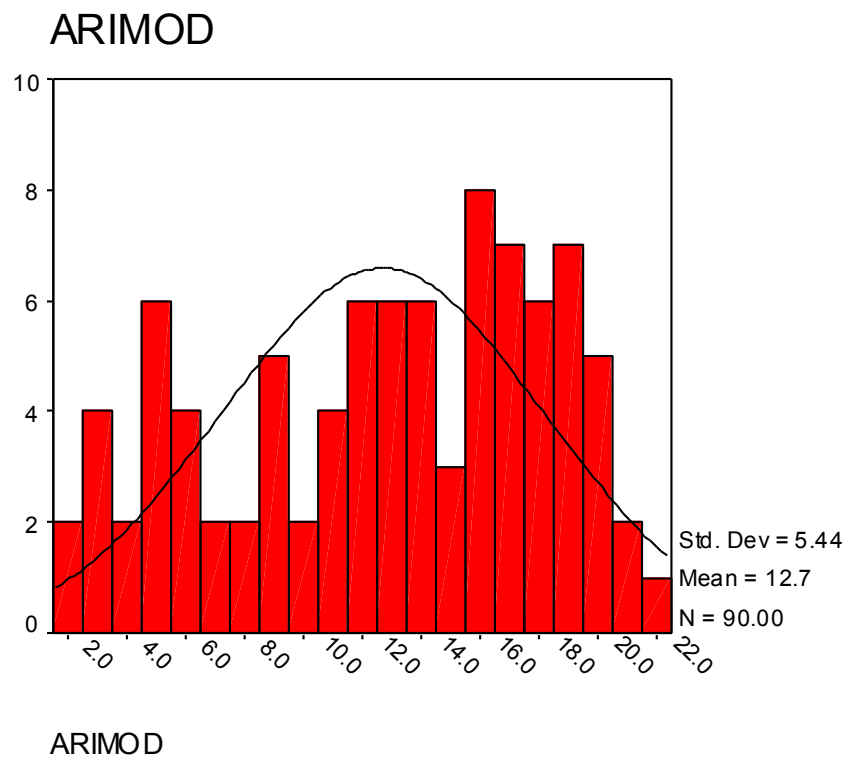
$$ARI = 4,71 \times (ch / w) + 0,5 \times (w / s) - 21,43$$

za tekstove na hrvatskom jeziku glasila bi:

$$ARI = 4,71 \times (ch / w) + 0,5 \times (w / s) - 23,23$$

gdje je ch = ukupan broj znakova; w = ukupan broj riječi; s = ukupan broj rečenica.

Opravdanost modifikacije postojeće formule za hrvatski jezik na ovaj način može se vidjeti iz slike 7., koja pokazuje pravilnu krivulju frekvencija odstupanja po pojedinim indeksima čitkosti analiziranih tekstova.

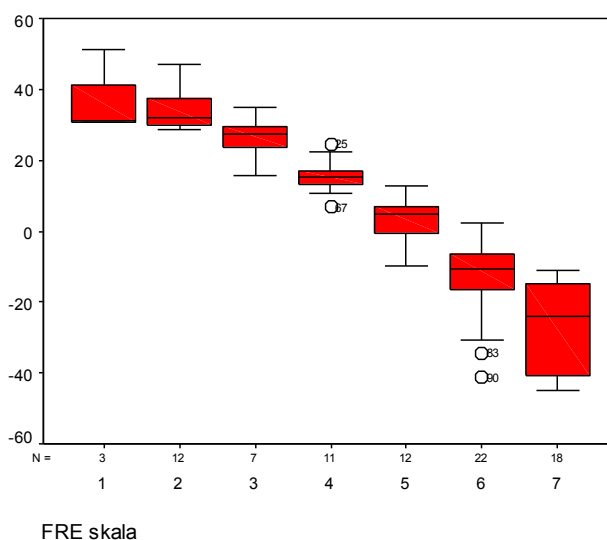


Slika 7. Frekvencije odstupanja modificirane formule ARI po pojedinim tekstovima na hrvatskom jeziku

Tablica 13. Indeksi čitkosti tekstova na hrvatskom jeziku, prema formuli FRE, na temelju opisne skale

FRE engleski				FRE hrvatski		
Red.br.	raspon	opis	n	raspon	prosjek	srednja vrijednost
1	90-100	vrlo lako	3	31-51	37,7	31,1
2	80-90	lako	12	29-47	34,1	31,8
3	70-80	donekle lako	7	16-35	26,2	27,3
4	60-70	standardno	11	7-25	15,6	15,2
5	50-60	donekle teško	12	-10-13	3,1	4,7
6	30-50	teško	22	-42-2	-13,3	-10,7
7	0-30	vrlo teško	18	-45- -11	-26,5	-24,2

Iz tablice 13. vidljivo je kako indeksi čitkosti tekstova na hrvatskom rastu s povećanjem složenosti tekstova, ali se dobiveni rezultati ne poklapaju s opisnom skalom definiranom za izvornu formulu FRE za engleski jezik. Pravilan porast indeksa čitkosti za tekstove na hrvatskom jeziku vidljiv je i u grafičkom prikazu na slici 8.



Slika 8. Trend indeksa čitkosti za tekstove na hrvatskom jeziku prema sedam stupnjeva opisne skale formule FRE

Polazeći od indeksa čitkosti prikazanih za pojedinačne tekstove na engleskom i hrvatskom jeziku u tablicama 7. i 8., izračunata je razlika prosječnih vrijednosti indeksa između ova dva jezika, koja iznosi 50, odnosno prosječna vrijednost je za toliko manja u hrvatskom jeziku. Stoga se predlaže modifikacija formule FRE za tekstove na hrvatskom jeziku kako slijedi:

postojeća formula FRE, koja za engleski jezik glasi:

$$\text{FRE} = 206,835 - 0,846 \text{ wl} - 1,015 \text{ sl}$$

modificira se za hrvatski jezik da glasi:

$$\text{FRE} = 206,835 - 0,846 \text{ wl} - 1,015 \text{ sl} + 50$$

gdje je wl = dužina riječi izražena brojem slogova, a sl = dužina rečenice izražena brojem riječi.

Pri tome se skala indeksa za engleski jezik, kako je prikazana u tablici 13., treba prilagoditi za dobivene indekse na hrvatskom jeziku kako bi se većina rezultata uklopila sa što manje pogrešaka u opisnu skalu na sljedeći način: 80-100 lako, 60-80 standardno, 50-60 donekle teško i 0-50 vrlo teško.

Formula Lix čitkost također izražava opisno na skali od najlakšeg do najtežeg teksta za razumijevanje: < 24 vrlo lagano; 25-34 lagano; 35-44 osrednje; 45-54 teško; > 55 vrlo teško. Polazeći od indeksa čitkosti prikazanih za pojedinačne tekstove na engleskom i hrvatskom jeziku u tablicama 7. i 8. za formulu Lix, izračunata je razlika prosječnih vrijednosti indeksa između ova dva jezika, koja iznosi 1,7, odnosno prosječna vrijednost je za toliko manja u hrvatskom jeziku. Stoga se predlaže modifikacija formule Lix za tekstove na hrvatskom jeziku kako slijedi:

postojeća formula Lix, koja glasi:

$$LIX = A/B + (C \times 100)/A$$

gdje je A = broj riječi, B = broj rečenica, C = broj dugih riječi (više od 6 znakova),

može se modificirati pojednostavljeno za hrvatski jezik da glasi:

$$LIX = A/B + (C \times 100)/A + 2$$

gdje je A = broj riječi, B = broj rečenica, C = broj dugih riječi (više od 7 znakova).

Dakle, osim zaokružavanja koeficijenta koji se uvrštava u formulu za hrvatski jezik, duge riječi se definiraju kao one od osam i više znakova, a postojeća opisna skala napravljena za izvornu formulu Lix se zadržava.

## 5. RASPRAVA

Cilj ove disertacije bio je izraditi, za potrebe zdravstvene komunikacije, model za izračunavanje čitkosti teksta koji će biti najprimjereniji za hrvatski jezik, a temeljit će se na postojećim formulama čitkosti za engleski jezik. Polazište je bila hipoteza da se postojeće formule čitkosti kakve postoje u obliku valjanom za engleski jezik ne mogu koristiti za tekstove na hrvatskom jeziku bez određenih modifikacija koje su nužne zbog razlika između ova dva jezika.

U tu je svrhu napravljena kontrastivna analiza tekstova na engleskom i hrvatskom jeziku različite očekivane težine za razumijevanje kako bi se dobio uvid u razlike između ova dva jezika u onim varijablama koje su nužne za izračun čitkosti prema formulama čitkosti.

Kako je za najčešće korištene formule čitkosti potreban izračun broja slogova i višesložnih riječi, a postojeći računalni programi ne daju uvijek identične rezultate, kao što je opisano i u literaturi [90], vrijednosti dobivene računalnim programima su uspoređene s rezultatima dobivenima ručnim računanjem izvornih govornika engleskog i hrvatskog jezika, kako je prikazano u tablicama 3. i 4., radi odabira najpouzdanijeg računalnog programa.

Tek nakon odabira adekvatnog računalnog programa obavilo se računanje neophodnih varijabli, jer bi ručno računanje usporilo proces izračuna čitkosti teksta za buduće tekstove namijenjene pacijentima. Tablice 5. i 6. prikazuju rezultate tih izračuna za one formule čitkosti koje se mogu prilagoditi hrvatskom jeziku, dok za neke formule čitkosti



to nije moguće, iako su opisane u ovom radu, zbog korištenja popisa najučestalijih riječi, koji je dostupan za engleski jezik, kao naprimjer Thorndikeov ili Dale-Chall popis riječi [90].

Iz tablica 5. i 6. vidljivo je kako se ukupan broj riječi, slogova i znakova, kao i višesložnih i dugih riječi povećava od najjednostavnijih vrsta tekstova do najsloženijih tj. od jednostavnih književnih tekstova (br.1-33 iz Priloga 1), preko reportaža (br.34-57 iz Priloga 1) i znanstveno-popularnih (br.58-75 iz Priloga 1) do znanstvenih članaka (br.76-90 iz Priloga 1). Ove četiri vrste teksta razlikuju se dakle po prosječnoj dužini i riječi i rečenice. Tako je raspon najjednostavnije vrste tekstova (br.1-33) po dužini rečenice 5,2-21,1 za engleski jezik i 4,7-18,2 za hrvatski jezik, a za znanstvene članke (br.76-90) iznosi 20,4-30,8 za engleski jezik i 19,2-31,4 za hrvatski jezik. Dakle, isti trend porasta prosječne dužine rečenice vidi se u oba jezika, a analizirani uzorak pokazuje da su u prosjeku rečenice u hrvatskom jeziku kraće.

Rezultati analize iskaza hrvatskih pacijenata o operaciji žuči [157] pokazali su da se prosječna dužina rečenica razlikovala po obrazovnom stupnju ispitanika te je iznosila u prosjeku 12 riječi za osobe s niskim obrazovanjem, 14 riječi za osobe sa srednjoškolskim obrazovanjem i 16 riječi za osobe s visokoškolskim obrazovanjem. Osobe s niskim obrazovanjem, tj. završenom ili nezavršenom osnovnom školom, izrazito su se više koristile kratkim rečenicama, a osobe s visokoškolskim obrazovanjem, tj. više od barem 12 godina školovanja, izrazito su se više koristile dugim rečenicama, dok kod osoba sa srednjoškolskim obrazovanjem razlike u dužini rečenica nisu bile toliko izražene. To je usporedivo s rezultatima analize tekstova iz ove radnje, gdje je prosječna dužina rečenice najjednostavnije vrste tekstova (br.1-33) bila

12 riječi u engleskom jeziku i 11 riječi u hrvatskom jeziku. Pri tome se kao najjednostavniji tekstovi po dužini rečenica pojavljuju odlomci autora Dana Browna (br.13,14,16-18), s rasponom od 5,2-7,3 riječi po rečenici u engleskom jeziku, a i prijevod na hrvatski odražava taj stil pisanja rasponom 4,7-7,3 riječi po rečenici.

Dužina rečenice svakako utječe na čitkost teksta, što pokazuju i indeksi formula čitkosti koje tu varijablu uzimaju u obzir, a također i brojna istraživanja čitkosti kroz povijest. Sherman [97] je svojim statističkim analizama pokazao kako prosječna dužina rečenice opada kroz vrijeme te je u njegovo doba iznosila 23 riječi, a u današnje vrijeme iznosi 20 riječi za engleski jezik [90]. Sherman zaključuje kako kraće rečenice i konkretni pojmovi povećavaju čitkost teksta, da je usmeni govor učinkovitiji od pisanog te da pisani govor postaje učinkovitiji što više nalikuje na usmeni govor [90]. I Flesch zastupa ideju da je čitko štivo ono koje je napisano na način kako govorimo. Daje podatke kako tipični časopis njegova vremena, tj. 40-tih godina 20. stoljeća sadrži rečenice koje u prosjeku imaju manje od 20 riječi. A kad bismo način govora prenijeli na papir, rečenice bi bile još kraće, svega 15-tak, a možda čak i 10-tak riječi po rečenici [106]. Ukratko, što je rečenica duža, povećava se težina teksta [145,153].

Veću čitkost tekstova jednostavnije literature iz uzorka ovog rada, koji često koriste dijaloge, pokazuju i rezultati ovog istraživanja, čemu bi trebali težiti materijali pisani za pacijente radi lakšeg razumijevanja teksta. Razlog je tome što su kraće rečenice sintaktički u pravilu i jednostavnije te samim time i lakše za razumijevanje [79]. Preporuka da se u materijalima za pacijente koriste kraće rečenice, s manje od 15 riječi, a poželjno bi bilo čak ispod 10 riječi, uz zadržavanje konverzacijskog stila, u skladu je s teorijom da je za pacijente prikladan tzv. model priče, a nipošto tzv. medicinski model,

jer je priča vrlo snažna, zaokuplja pažnju čitatelja i zanimljiva je pa čitatelji ne odustaju od čitanja. Medicinski model, gdje se opisuje bolest, rizici, liječenje, nuspojave i ostalo može se primijeniti jedino kod materijala za one pacijente koji žele detaljnije informacije [14]. U tom su smislu napravljene i ostale preporuke za pisanje informacija za pacijente, polazeći od činjenice da su znanstvene informacije općenito po svojoj prirodi preteške za razumijevanje pa ih treba pojednostavniti odnosno prilagoditi čitateljstvu [38]. Prilagodba je nužna jer se pokazuje da liječnici i pacijenti žive u dva različita svijeta i govore različitim jezicima pa liječnici u svojoj komunikaciji s pacijentima moraju prevesti svoje znanje u jezik koji njihovi pacijenti mogu razumjeti [4]. To je iznimno važno za uspješnu komunikaciju u poimanju suvremenog odnosa liječnik-pacijent, gdje je zdravstvena zaštita orijentirana ka pacijentu te bi probleme pacijenta trebalo sagledati iz perspektive pacijenta. Osim toga, pacijent se kao ravnopravan sudionik u toj komunikaciji također pojavljuje kao stručnjak, iako laik, pa ga se uključuje u izradu i odlučivanje o konačnoj verziji pisanih materijala za pacijente [4]. Istraživanje načina izražavanja hrvatskih pacijenata čak nudi profil pacijenta koji bi bio najbolji laički komunikator zdravstvenih informacija [159].

Usporedbom tablica 5. i 6. također je vidljivo da je dužina riječi ne samo mjerena brojem slova nego i brojem slogova u prosjeku veća u hrvatskom jeziku, što ukazuje na potrebu modifikacije formula čitkosti napravljenih za engleski jezik kada se one koriste na tekstovima na hrvatskom jeziku. Autor formule SMOG, McLaughlin, otkriva da u engleskom jeziku ukupan broj slogova u uzorku iznosi otprilike jednu trećinu ukupnog broja slova [158], što pokazuju i rezultati ovog istraživanja u tablici 5., a u hrvatskom jeziku je taj postotak nešto veći te iznosi otprilike 40% ukupnog broja slova po odlomku, kao što se vidi iz tablice 6. Budući da je pretpostavka da su tekstovi na

engleskom i hrvatskom jeziku iz ovog uzorka ekvivalenti po svojoj čitkosti, s obzirom da su prijevodni ekvivalenti, ta razlika se može objasniti kompenziranjem hrvatskog jezika kroz svoju ortografsku transparentnost. Do sličnih zaključaka dolaze i autori formula SOL, koji su modificirali postojeću formulu SMOG za engleski jezik tako da odgovara tekstovima na francuskom i španjolskom jeziku [94]. Jednaka čitkost prijevodnih ekvivalenata uz istovremeni veći broj slogova u hrvatskom u odnosu na engleski jezik, može se objasniti, pored ortografske transparentnosti hrvatskog jezika, i postojanjem gramatičkih nastavaka u hrvatskom jeziku, koji općenito povećavaju dužinu riječi, ali povećavaju i redundantnost u jeziku, što znači da čitatelj tekstova na hrvatskom jeziku zna što može očekivati u riječima koje slijede, a gramatičke kategorije mu olakšavaju razumijevanje pročitano. To se podudara i s tvrdnjom McLaughlina da je težina teksta u semantičkom i sintaktičkom smislu povezana s pohranom u kratkotrajnom pamćenju [158]. Novija istraživanja upravo pokazuju da je za tečno čitanje neophodno automatizirano prepoznavanje riječi kako bi se oslobodio kapacitet pažnje za razumijevanje [83], a tečno čitanje dovodi i do preciznosti u čitanju tj. pročitano se točno i precizno interpretira [79]. Riječi koje se češće koriste brže se i prepoznaju, lakše ih je razumjeti i brže se mogu naučiti [102]. Najfrekventnije riječi su obično kraće, što direktno utječe na razumijevanje [20,79]. Riječi koje prve naučimo su najjednostavnije i najkraće, a ujedno se pokazuje da su i najčešće. Osim toga, najčešće riječi pokrivaju velik dio ukupnog vokabulara, naprimjer 10 najčešćih riječi može pokrivati i do 25% ukupno korištenih riječi u nekom tekstu [99]. Time vokabular predstavlja jaki prediktor težine teksta [98], štoviše, Chall, autor jedne od formula čitkosti čak pokazuje da je težina vokabulara ustvari najjači prediktor težine teksta [88]. To itekako utječe na proces čitanja i razumijevanja, jer se pokazuje da loši čitači preskaču nepoznate riječi, neke doslovno shvaćaju, stoga ne shvaćaju kontekst, zato se

brzo umaraju čitajući i ne razumiju pročitano [58]. Za lingviste sociološkog i psihološkog usmjerenja vokabular pojedinca ili određene skupine ili cijele zajednice te način njegova korištenja predstavljaju izuzetno važnu karakteristiku. Stoga se istraživanja komunikacije velikim dijelom moraju oslanjati na ovakve statističke proračune i matematičke metode, koje uključuju podatke o učestalosti, opsegu varijacija i srednjim vrijednostima [20]. Rezultati ovog istraživanja su u skladu sa Zipfovim načelom najmanjeg truda [101], koje tvrdi da govornik teži što više koristiti iste riječi, a slušatelj traži maksimalnu jasnoću, odnosno drugim riječima, s jedne strane postoji težnja da se uloži što manje truda, a s druge strane je težnja za razumljivošću. U stvarnom govoru te se krajnosti pomiruju i pokazuju očuvanje energije, što je središnja karakteristika jezika [101]. Tako odlomci autora Dana Browna iz uzorka ove radnje, naročito br. 14. i 18. iz Priloga 1 pokazuju da je unutar 30 rečenica korišteno najmanje riječi, da su u prosjeku te riječi bile najkraće, a kasnije se u rezultatima vidi i da je čitkost po formulama čitkosti za te odlomke bila najveća.

Tablice 7. i 8. prikazuju rezultate formula čitkosti za tekstove na engleskom i na hrvatskom jeziku, a korištene formule su one koje su primjerene za odraslu populaciju, za zdravstvenu komunikaciju te ih je moguće bez većih poteškoća primijeniti na hrvatski jezik. Iz samih vrijednosti indeksa je vidljivo da indekse čitkosti dobivene za engleski jezik ne možemo koristiti za komunikaciju na hrvatskom jeziku, već je potrebna konverzija indeksa, odnosno modifikacija formula, kako bi se točnije izrazila težina teksta na hrvatskom jeziku. Također je vidljivo kako indeksi čitkosti pokazuju očekivanu veću čitkost jednostavnijih književnih tekstova, a manju čitkost složenijih, popularno-znanstvenih i znanstvenih tekstova, u oba jezika. Konkretno vrijednosti po pojedinim formulama se razlikuju budući da izražavaju s jedne strane različite pojmove,

a s druge strane očekivana minimalna odstupanja po različitim formulama. Tako, naprimjer, formule SMOG, Kincaid i ARI izražavaju broj godina školovanja, FRE se mjeri na skali od 0-100, gdje je 100 najveća čitkost odnosno najjednostavniji način izražavanja, a vrijednosti za formulu Lix također izražavaju skalu, gdje su indeksi ispod 25 jako lagan, a iznad 55 jako težak tekst za razumijevanje.

Postoje očekivana odstupanja po formulama koje indeksom čitkosti označavaju broj godina školovanja nužnih za razumijevanje određenog teksta. Tome je uzrok ne samo različit način računanja čitkosti, tj. uvrštavanje različitih varijabli i njihov međudnos u formuli, već i način izrade i validiranje formule odnosno očekivani postotak razumijevanja kod ispitanika. Formula SMOG je nastala regresijskom analizom i povezana je s točnošću razumijevanja od 100%. Formula Kincaid nastala je na temelju Fleschove formule, za potrebe američke mornarice, kako bi se na jednostavniji način izrazila težina teksta, tj. ne više opisno na skali težine kao kod formule FRE, već stupnjem školovanja koji bi osoba trebala imati da može razumjeti određeni tekst, a Fleschova formula se temeljila na 75%-tnoj točnosti rješavanja testa [90], što je puno manje nego kod formule SMOG. Formula ARI se temelji na broju znakova i uopće ne uzima u obzir broj slogova, ali indeksi čitkosti prilično dobro odgovaraju indeksima dobivenima za formulu Kincaid za engleski jezik, uz prihvatljivo odstupanje od otprilike 2 stupnja (tablica 7).

Iako kritičari formula čitkosti vrlo često navode upravo ta odstupanja u indeksima među različitim formulama kao argumente protiv korištenja formula, mora se uzeti u obzir kako formule koreliraju s testovima razumijevanja. Pokazuje se da formule s višim kriterijem točnosti daju više vrijednosti indeksa čitkosti. Ono što je važnije od

neidentičnih indeksa čitkosti za isti tekst prema različitim formulama je dosljednost u procjeni težine različitih tekstova uz primjenu iste formule [90]. Ta dosljednost je vidljiva u rezultatima prikazanim u tablicama 7. i 8., za engleski i za hrvatski jezik.

Također, raspon indeksa po različitim formulama samo nas podsjeća da indeksi čitkosti nisu precizne vrijednosti, već se prije mogu nazvati izrazom vjerojatnosti ili procjenom težine [90]. To se, uostalom, i naglašava u samim definicijama formula čitkosti, koje formule čitkosti nazivaju grubim vodičima [139], jer je poznato ne samo da indeks čitkosti po određenoj formuli pokazuje točnost otprilike  $\pm 1-1,5$  stupanj, nego da i razlike u indeksima po različitim formulama mogu biti 1-2 stupnja [56].

Stručnjaci iz ovog područja preporučuju da tekstovi namijenjeni široj publici, kao npr. uputstva za uzimanje lijekova, za ispunjavanje poreznih kartica ili rukovanje različitim uređajima, ali i zdravstvene informacije, trebaju biti napisani na najjednostavniji mogući način [98]. Istraživanja čitkosti temeljena na formulama čitkosti obuhvaćaju vrlo raznolika područja, npr. informacije za pacijente u palijativnoj skrbi [160], informacije o mentalnom zdravlju [161], o dentalnom zdravlju [162], o zdravom okolišu [163], informacije za informirani pristanak [164], za sudjelovanje pacijenata u kliničkim istraživanjima [165-167], informacije za pacijente na Internetu [61,63,168] te medicinske časopise [169]. Bez obzira koja je formula bila korištena, većina studija pokazuje da su informacije bile napisane na razini težine teksta koja je previsoka za publiku kojoj je namijenjena. Drugim riječima, postoji nesrazmjer zdravstvene pismenosti pojedinca i razine čitkosti materijala namijenjenih pacijentima [59-63]. Istraživanja u svijetu pokazuju taj nesrazmjer kod različitih populacijskih skupina, također kod neengleskog govornog područja [64], s obzirom na različite zdravstvene

teme te različite oblike prezentacije ili medije korištene za zdravstvene informacije [53]. Općenito, liječnici često nisu svjesni nesrazmjera između svog načina komuniciranja s pacijentima i pacijentove sposobnosti shvaćanja, pamćenja i djelovanja na osnovu dobivenih informacija [50]. Naprimjer, pokazuje se da je više od polovice pisanih materijala za pacijente preteško za prosječnog stanovnika SAD-a, a u odrasloj populaciji SAD-a čak je 20% funkcionalno nepismenih [58]. O tom nesrazmjeru samo u SAD-u svjedoči preko 300 studija [59]. Adekvatna čitkost pisanih materijala, odnosno prilagođena razina težine teksta specifičnoj ciljnoj populaciji, važna je ne samo kod prikupljanja podataka od ispitanika kako bi podaci bili vjerodostojni i usporedivi s drugim populacijama, već i kod informativnih materijala za edukaciju pacijenata te ključnih dokumenata koji jamče aktivnu ulogu pacijenta u odlučivanju o vlastitom zdravlju, kao naprimjer informirani pristanak, koji ima i zakonske posljedice. Stoga nije neuobičajeno da se razina čitkosti raznovrsnih pisanih materijala definira u određenim državama kao obvezujuća za određenu ciljnu populaciju ne samo kroz formulaciju lakorazumljivog teksta, već i kroz konkretnu mjeru čitkosti. Tako npr. većina Amerikanaca ima sposobnost čitanja na razini 6. do 8. razreda, tj. stupanj čitalačke sposobnosti prosječnog Amerikanca iznosi 7,5 [65], a niska pismenost britanske populacije razlog je zašto se za zdravstvene informacije zahtijeva stupanj težine teksta po formuli SMOG  $\leq 5$  [66] kako bi takve informacije mogla razumjeti većina ljudi u Velikoj Britaniji. U Hrvatskoj se “Zakonom o zdravstvenoj zaštiti” iz 1993. godine [67], članak 25., stavak 6., jamči da pacijent ima “pravo na točno informiranje i poduku o svim pitanjima koja se tiču njegova zdravstvenog stanja” te se u Zakonu o zaštiti prava pacijenata iz 2004. godine [68] navodi da “pacijent ima pravo dobiti obavijesti na način koji mu je razumljiv s obzirom na dob, obrazovanje i mentalne sposobnosti”, a istovremeno jezična analiza tekstova za pacijente sa šećernom bolešću pokazuje da



prosječno težak tekst, napisan na razini 12 godina školovanja, ne bi razumjelo skoro 80% stanovništva starijeg od 15 godina, prema popisu stanovništva iz 1991. godine [64], odnosno skoro 70% stanovništva prema popisu iz 2001. godine [69]. Stoga ne iznenađuju rezultati nedavnog istraživanja percepcije bolesti i kardiovaskularnih faktora rizika kod pacijenata sa šećernom bolešću u Hrvatskoj, koji pokazuju da je upravo slabo razumijevanje vlastite bolesti povezano s lošijim ishodima liječenja i zdravstvenim ponašanjem kod ove kronične bolesti [70]. I rezultati magistarskog rada autorice ove disertacije pokazuju da tekst namijenjen pacijentima, koji po modificiranoj formuli SMOG pokazuje da je bio napisan na razini 11 godina školovanja, većina testiranih pacijenata nije razumjela. Tekst je bio prihvatljiv za 96% ispitanika s visokoškolskim obrazovanjem, za 57% ispitanika sa srednjoškolskim obrazovanjem, ali niti za jednog ispitanika sa završenom ili nezavršenom osnovnom školom [157]. Na državnoj razini, u Republici Hrvatskoj ima 1,8% nepismene populacije, a čak 40,4% odrasle populacije ima tek završenu ili nezavršenu osnovnu školu, kako je registrirano popisom stanovništva iz 2001. godine [71]. Ako se uzme u obzir da je sposobnost čitanja pojedinca do tri godine niža od stupnja završenog obrazovanja, može se reći da zdravstvene informacije namijenjene općoj populaciji u Hrvatskoj ne bi smjele biti više od razine težine 5 ili 6 godina školovanja, kad se računa formulama čitkosti. Analiza tekstova iz uzorka ove disertacije pokazuje da je način pisanja autora Dana Browna primjeren za ovakav stupanj školovanja, jer se težina teksta pokazala kao vrlo lagana. Da je takav način izražavanja moguć i kada se radi o informacijama za pacijente, pokazuju rezultati analize iskaza pacijenata o operaciji žuči [157], koji ustvari predstavljaju laički opis zdravstvenog stanja i liječenja tih pacijenata. Prema modificiranoj formuli SMOG, prosječni indeks tih transkribiranih iskaza bio bi 6 kod

osoba sa završenom ili nezavršenom osnovnom školom, 7 kod osoba sa srednjoškolskim obrazovanjem te 8 kod osoba s visokoškolskim obrazovanjem.

Usporedba indeksa za tekstove na engleskom i hrvatskom jeziku prikazana je u tablicama 9.-12., za formule SMOG, Kincaid, ARI, FRE i Lix, jer one predstavljaju različite modela računanja i izražavanja težine teksta. Formula SMOG za varijablu uzima samo ukupni broj višesložnih riječi, Kincaid uzima u obzir dužinu rečenice i prosječni broj slogova u riječima, ARI uzima u obzir dužinu rečenice i dužinu riječi mjerenu brojem znakova, FRE dužinu rečenice i dužinu riječi u slogovima, a Lix dužinu rečenice i broj dugih riječi. Dobiveni indeksi pokazuju da se bilo koji model odnosno formula može koristiti za računanje težine teksta i da će pokazati veću razinu težine kod očekivano zahtjevnijih tekstova, ali isto tako da se uzlazni trend opažen na tekstovima na engleskom jeziku pokazuje i na tekstovima na hrvatskom jeziku. Slike 1.-4. dodatno i grafički prikazuju te uzlazne trendove, ali i podudarnost između indeksa na engleskom i na hrvatskom jeziku, uz određenu prilagodbu. Stoga je modifikacija postojećih formula čitkosti validiranih za engleski jezik moguća za tekstove na hrvatskom jeziku, na temelju rezultata usporedbe indeksa čitkosti po pojedinim formulama, kako je prikazano u tablicama 9.-12. U tu je svrhu dodatno za formulu čitkosti SMOG izračunat indeks čitkosti za hrvatski jezik definirajući pojam višesložnosti riječi kao riječi sa četiri i više sloga, budući da je ova formula poznata kao formula čitkosti koja se ručno računa, a zbog veće dužine riječi izražene brojem slogova u hrvatskom jeziku ručno računanje trosložnih riječi ne može se smatrati prednošću pred računalnim izračunom. Također je dodatno izračunat indeks čitkosti po formuli Lix za tekstove na hrvatskom jeziku, gdje se duga riječ definira kao ona od osam i više znakova odnosno slova.

Modifikacija formula čitkosti za hrvatski jezik napravljena je kako na temelju usporedbe indeksa u engleskom i hrvatskom jeziku, tako i uvidom u vrijednosti nužnih za pojedine formule, a s ciljem što jednostavnije prilagodbe formule za hrvatski jezik. Dodatno su se iskoristile prednosti hrvatskog jezika u smislu olakšavanja računanja višesložnih i dugih riječi.

Tako je za formulu SMOG modifikaciju usmjerila činjenica da su u hrvatskom jeziku riječi u prosjeku duže po broju slogova te da ukupni broj slogova u analiziranim tekstovima iznosi otprilike 40% ukupnog broja znakova, za razliku od engleskog jezika, gdje iznosi otprilike jednu trećinu, kao što se pokazuje i u literaturi [158]. Tako se formula SMOG za hrvatski jezik predlaže u vrlo jednostavnom obliku, kao što se pojavljuje i u originalu, a to je i bio cilj autora McLaughlina [111]. Osim toga, budući da je za ovu formulu predviđeno ručno računanje broja višesložnih riječi, izračun ove varijable za hrvatski jezik prema modificiranoj formuli je puno brži nego što bi to bilo kod računanja prema izvornoj formuli.

Modifikacija formule SMOG napravljena je i za francuski i španjolski jezik pod nazivom SOL [94], ali na način koji je vrlo kompleksan, jer nakon što se izvorna formula primijeni na tekstovima na francuskom i španjolskom jeziku, potrebno je dodatno izračunati složenu konverziju uzimajući u obzir indeks čitkosti na engleskom jeziku. Autori prilažu i tablicu za konverziju indeksa radi lakšeg snalaženja, ali su razlike među indeksima nedosljedne pa djeluju nepouzdana. Budući da su francuski i španjolski jezik ortografski transparentniji od engleskog jezika, a autori pokazuju i da je postotak višesložnih riječi u ta dva jezika veći nego u engleskom jeziku, može se

pretpostaviti da bi model računanja primijenjen za hrvatski jezik mogao dati i jednostavniji način računanja i jednostavniju formulu i za francuski i španjolski jezik.

Za formulu Kincaid predložena modifikacija se temelji na prosječnoj razlici vrijednosti između indeksa čitkosti dobivenih za tekstove na engleskom i hrvatskom jeziku. Primijenjena minimalna intervencija u izvornu formulu pokazuje se opravdanom, jer su uzlazni trendovi indeksa u oba jezika usporedivi, a iz slike 5. se vidi da su odstupanja po pojedinim izračunatim indeksima za hrvatske tekstove prihvatljiva. Međutim, budući da dobiveni indeksi i u engleskom jeziku pokazuju veliki raspon, a svaki indeks nije potkrijepljen velikim brojem tekstova iz uzorka, ova se formula čitkosti ne može preporučiti za zdravstvenu komunikaciju na hrvatskom jeziku kao formula čitkosti prvog izbora.

Formula ARI također pokazuje usporediv uzlazni trend indeksa čitkosti za tekstove na engleskom i hrvatskom jeziku, ali je ponovno raspon indeksa vrlo širok i pojedini indeksi nisu potkrijepljeni dovoljnim brojem tekstova iz uzorka da bi se ova formula preporučila za zdravstvenu komunikaciju na hrvatskom jeziku. Modifikacija je ipak napravljena te je prikazana njena opravdanost kroz prihvatljiva odstupanja pojedinih indeksa za tekstove na hrvatskom jeziku, kako je vidljivo na slici 7.

Fleschova formula FRE i formula Lix izražavaju čitkost kroz opisnu težinu na skali. Modifikacijom formule FRE za tekstove na hrvatskom jeziku modificira se i skala, kako je opisano u rezultatima, što ustvari pojednostavljuje njeno korištenje u praksi, u primjeni na tekstovima namijenjenima pacijentima. Modifikacija je napravljena uz minimalnu intervenciju u izvornu formulu, a budući da je ova formula često sastavni dio

računalnih programa za obradu teksta, može se preporučiti za zdravstvenu komunikaciju na hrvatskom jeziku.

Kod formule Lix se opisna skala zadržava pri modifikaciji formule za tekstove na hrvatskom jeziku, ali budući da je računanje dugih riječi, čak i kada se taj pojam poveća u broju znakova, iznimno sporo i podložno pogreškama, jer je nužno ili ručno računanje ili pristup računalnim programima dostupnima na Internetu kod kojih je opet potrebno preračunavanje [156] ili koji su možda privremeno dostupni [126], ova se formula čitkosti ne preporuča kao prvi izbor u zdravstvenoj komunikaciji na hrvatskom jeziku.

Na temelju rezultata ovog istraživanja može se zaključiti da se formule čitkosti u svom modificiranom obliku mogu preporučiti za testiranje težine pisanih materijala za pacijente kao prvi pokazatelj težine teksta, jer su brza, jeftina i učinkovita metoda. Nasuprot tome, subjektivna procjena težine teksta je nepouzdana, testiranje gotovih zdravstvenih materijala na pacijentima je opsežan i dugotrajan proces, a primjena testova čitanja za hrvatski jezik zbog svoje ortografske transparentnosti nije moguća kao ni za španjolski jezik [75]. Nadalje, primjena testova razumijevanja također zahtijeva određena ulaganja te preostaje upotreba formula čitkosti kao gruba procjena težine pisanih materijala, ali koja ionako jako dobro korelira s rezultatima testova razumijevanja [90].

Formule čitkosti kao pokazatelji težine teksta kod različitih pisanih materijala za pacijente imaju važnu ulogu s komunikacijskog, ali i obrazovnog aspekta. Svrha suvremenog pokreta zdravstvene pismenosti jest poboljšanje zdravstvenih ishoda i smanjenje nejednakosti u zdravlju kroz poboljšani sustav zdravstvene komunikacije i

programe zdravstvenog odgoja [170]. Zdravstvena pismenost je najjači prediktor zdravstvenog stanja pojedinca [44], a u općoj populaciji postoje različite razine pismenosti pojedinih skupina. Testiranje zdravstvene pismenosti za govornike engleskog govornog područja vrlo često koristi test TOFHLA [57], koji navodi točne indekse čitkosti pojedinih dijelova koristeći jednu od formula čitkosti, a verzije ovog testa za druge jezike svakako bi trebale također navesti težinu tekstova kojima se testira zdravstvena pismenost.

Stupanj zdravstvene pismenosti direktno je povezan s uspješnošću komunikacije, što uvelike utječe na suradljivost pacijenata, ishod liječenja, učestalost korištenja zdravstvene zaštite, troškove i ukupnu kvalitetu zdravstvene zaštite [2-5]. Stoga se preporučuje, kako bi odaslane poruke bile jasne i razumljive svima, da se u formalno obrazovanje liječnika i ostalih zdravstvenih djelatnika uključe znanja i vještine iz područja zdravstvene pismenosti [171]. S komunikacijskog i etičkog stajališta, adekvatna zdravstvena komunikacija, koja uzima u obzir stupanj pismenosti pojedinca, povećava pristupačnost zdravstvenoj zaštiti i jača aktivnu ulogu pacijenta u zdravstvenom sustavu, što je temelj kvalitetnog odnosa između liječnika i pacijenta, ali i zdravstvene politike kojoj je cilj povećanje sveukupne kvalitete zdravstvene zaštite te zaštite prava pacijenata.

Osim toga, kako se pojam zdravstvene pismenosti ograničava na razinu pojedinca, nastao je i prošireni pojam koji uključuje razinu zajednice, nazvan javnozdravstvena pismenost, a definira se kao “stupanj do kojega su pojedinci i skupine sposobni doći do, obraditi, razumjeti, procijeniti i djelovati na temelju informacija potrebnih za donošenje javnozdravstvenih odluka koje služe na dobrobit zajednici” [170]. Dakle, razina zdravlja

pojedince se proširuje na razinu zdravlja zajednice u najširem smislu, gdje u komunikaciji sudjeluju uz laike i stručnjaci najraznovrsnijih profila. Formule čitkosti u tom kontekstu javnozdravstvene pismenosti još više dobivaju na važnosti, jer se može za pojedine skupine ili širu populaciju preporučiti poželjna težina teksta, koja će odgovarati pismenosti ciljne populacije.

Na kraju, formule čitkosti su svoju vrijednost dokazale kroz desetljeća primjene i istraživanja, preživjele su kritike, a u zdravstvenoj komunikaciji na hrvatskom jeziku tek trebaju zaživjeti.

## 6. ZAKLJUČCI

Na temelju rezultata provedenog istraživanja o formulama čitkosti i rezultata ove disertacije, mogu donijeti sljedeće zaključke:

1. rezultati formula čitkosti pokazuju očekivane razine težine za četiri vrste analiziranih tekstova iz uzorka;
2. uzlazni indeksi čitkosti za engleski jezik pokazuju isti uzlazni trend za hrvatski jezik kod analiziranih tekstova;
3. viši rezultati formula čitkosti za hrvatski jezik za iste prijevodne tekstove pokazuju da je hrvatski jezik čitkiji od engleskog, vjerojatno zbog ortografske transparentnosti hrvatskog jezika i obilje redundantnih gramatičkih elemenata;
4. konverzija indeksa čitkosti moguća je s engleskog za hrvatski jezik zbog pravilnosti trendova indeksa u analiziranim tekstovima te nije nužno stvarati nove formule, već je moguće modificirati za hrvatski jezik već postojeće validirane formule čitkosti za engleski jezik;
5. formule čitkosti se preporučuju za testiranje težine pisanih materijala za pacijente kao prvi pokazatelj težine teksta, jer su brza, jeftina i učinkovita metoda, čiji rezultati dobro koreliraju s testovima razumijevanja.



## 7. SAŽETAK

Cilj ove disertacije je razvoj modela za kvantitativnu ocjenu kompleksnosti pisanih materijala, što je polazište za izradu instrumenta za ocjenu zdravstvene pismenosti, a takav model ni instrument ne postoje za hrvatski jezik. Adekvatna čitkost pisanih materijala, odnosno prilagođena razina težine teksta specifičnoj ciljnoj populaciji, važna je ne samo kod prikupljanja podataka od ispitanika, već i kod tekstova za edukaciju pacijenata i dokumenata koji jamče aktivnu ulogu pacijenta u odlučivanju o vlastitom zdravlju. U ovom je radu kontrastivnom analizom tekstova na engleskom jeziku i njihovih postojećih prijevoda na hrvatskom jeziku omogućen uvid u one varijable jezika koje su nužne za računanje čitkosti pisanih materijala upotrebom formula čitkosti. Postojeće formule čitkosti validirane za engleski jezik mogu se koristiti za tekstove na hrvatskom jeziku uz konverziju indeksa čitkosti odnosno modifikaciju formula kako je prikazano u rezultatima ovog istraživanja, jer pokazuju usporedive trendove indeksa. Preporučuje se upotreba formula čitkosti za grubu procjenu težine pisanih materijala za pacijente, jer zbog ortografske transparentnosti hrvatskog jezika nije moguće korištenje testova čitanja za testiranje razumijevanja, a formule čitkosti dobro koreliraju s testovima razumijevanja. Važnost ovog rada ogleda se i u mogućoj praktičnoj primjeni rezultata ovog istraživanja kod pripreme pisanih materijala za pacijente, jer se očekuje da to može pridonijeti smanjivanju zdravstvenih nejednakosti u korištenju zdravstvene zaštite s komunikacijskog aspekta, što bi za posljedicu trebalo imati veću orijentiranost ka pacijentu u odnosu liječnik-pacijent, te povećanje kvalitete zdravstvene zaštite uz istodobno smanjenje troškova u zdravstvenom sustavu.

## **8. SUMMARY**

### **DEVELOPING READABILITY FORMULAS FOR HEALTHCARE COMMUNICATION IN CROATIAN LANGUAGE**

The aim of this PhD thesis is to develop a model for quantitative assessment of written text complexity. This will be the basis for developing an instrument for health literacy assessment, as neither the readability formula nor the health literacy assessment instrument exist yet for Croatian language. Adequate readability of written materials, i.e. text complexity tailored to a specific target population, is important for collection of patient data, for patient educational materials, and for documents which will guarantee the active role of patients in making healthcare decisions. Contrastive analysis of texts in English and their existing translations in Croatian language provided an insight into text variables necessary for readability assessment by readability formulas. The existing readability formulas validated for English language may be used for Croatian texts provided the formulas are modified or their scores converted as presented here, because the score trends are comparable. Readability formulas are recommended here as rough estimates of the difficulty of written materials for patients since reading tests applied to test comprehension are not applicable for Croatian language because of its orthographic transparency, and readability formulas correlate well with comprehension tests. The importance of this study lies in the potential practical application of its results in the preparation of written materials for patients since it may contribute to decreasing the health inequalities in the use of healthcare services from the aspect of communication. This should result in a more dominantly patient-centred health care, increased quality of health care, and reduced health care costs.

## 9. LITERATURA

1. The health literacy problem in the USA. (editorial) *Lancet* 2009;374:2028.
2. Stewart M. Effective physician-patient communication and health outcomes: a review. *Can Med Assoc J* 1995;152:1423-33.
3. Kaplan RM. Shared decision making: a new tool for preventive medicine. *Am J Prev Med* 2004;26:81-3.
4. Roter DL, Hall JA. *Doctors talking with patients/patients talking with doctors*. Westport, London: Auburn House; 1992.
5. Waitzkin H. Changing patient-physician relationship in the changing health-policy environment. U: Bird CE, Conrad P, Fremont AM (ur.). *Handbook of medical sociology*. 5.izd. New Jersey: Prentice Hall; 2000., str. 271-83.
6. Whitney SN, McGuire AL, McCullough LB. A typology of shared decision making, informed consent, and simple consent. *Ann Intern Med* 2004;140:54-9.
7. Scheibler F, Janssen C, Pfaff H. Shared decision making: an overview of international research literature. *Soz Praventiv Med* 2003;48:11-23.
8. Šošić Z. *Osnove medicinske etike*. U: Grmek MD, Budak A (ur.): *Uvod u medicinu*. Nakladni zavod Globus, Zagreb, 1996., str. 225-34.
9. Lidz CW, Appelbaum PS, Meisel A. Two models of implementing informed consent. *Arch Intern Med* 1988;148:1385-9.
10. Vrhovac B. *Informed consent in Croatia*. U: *Informed consent in European reality*. International symposium on biomedical ethics. February 26-27, 1999, Zagreb, Croatia, str. 4-10.
11. ten Have H. *Problems of informed consent in the practical setting: beginners and usual suspects*. International symposium on biomedical ethics. February 26-27, 1999, Zagreb, Croatia, str. 51-7.
12. Wale J. *The role of the Cochrane Collaboration for consumers*. Cochrane Consumers and Communication Review Group, Victoria, Australia, 2001.
13. Cassell EJ. *Talking with patients: The theory of doctor-patient communication*. (Vol.1). The MIT Press, Cambridge, London, 1985.
14. Doak CC, Doak LG, Root JH. *Teaching patients with low literacy skills*. J. B. Lippincott Company (2. izd.), Philadelphia 1996.
15. Schillinger D, Grumbach K, Piette J, Wang F, Osmond D, Daher C, et al. Association of health literacy with diabetes outcomes. *JAMA* 2002;288:475-82.
16. Lloyd AJ, Hayes PD, London NJM, Bell PRF, Naylor AR. Patient's ability to recall risk associated with treatment options. *Lancet* 1999;353:645-6.

17. Gattellari M, Butow PN, Tattersall MHN. Informed consent: what did the doctor say? (comment) *Lancet* 1999;353:1713.
18. Škiljan D. Sloboda jezika. *SOL* 7/1988.
19. Reardon KK. Interpersonalna komunikacija: gdje se misli susreću. *Alinea*, Zagreb 1988.
20. Malmberg B. Moderna lingvistika. Slovo ljubve, Beograd 1979.
21. Kliment A. Poslovne komunikacije. Školska knjiga, Zagreb 1993.
22. Srića V. Principi modernog menedžmenta. Zagrebačka poslovna škola, Zagreb 1992.
23. Baker M. (ur.) *Routledge Encyclopedia of Translation Studies*. Routledge University Press, London, New York, 2000.
24. Hayes DP. *LEXGUIDE-2003: A guide to the lexical analysis of natural texts using QLEX or QANALYSIS*. [www.soc.cornell.edu/hayes-lexical-analysis](http://www.soc.cornell.edu/hayes-lexical-analysis)
25. Težak S. Hrvatski naš svagda(š)nji. Školske novine, Zagreb, 1990.
26. Tuckett D. Doctors and patients. U: Tuckett D (ur.). *An introduction to medical sociology*. Tavistock Publications, London-New York, 1976., str. 190-224.
27. Cerjan-Letica G, Letica S, Babić-Bosanac S, Mastilica M, Orešković S (ur.): *Medicinska sociologija*. Medicinska naklada, Zagreb, 2003.
28. Tattersall M. Humour and wisdom in medical ethics. *Lancet* 1999;353:1022-3.
29. Bukovčan D. *Jezik struke*. Hrvatsko društvo za primijenjenu lingvistiku, Opatija 2001.
30. Cockerham WC. *Medical Sociology*. Prentice Hall, New Jersey, 1995.
31. Simpson M, Buckman R, Stewart M, Maguire P, Lipkin M, Novack D, Till J. Doctor-patient communication: the Toronto consensus statement. *BMJ* 1991;303:1385-7.
32. Cerjan-Letica G, Letica S. Medicinske profesije. U: Cerjan-Letica G, Letica S, Babić-Bosanac S, Mastilica M, Orešković S (ur.): *Medicinska sociologija*. Medicinska naklada, Zagreb, 2003., str. 173-197.
33. Orešković S. Liječnička profesija. U: Grmek MD, Budak A (ur.): *Uvod u medicinu*. Nakladni zavod Globus, Zagreb, 1996., str. 208-24.
34. Ong LML, de Haes JCJM, Hoos AM, Lammes FB. Doctor-patient communication: a review of the literature. *Soc Sci Med* 1995;40(7):903-18.
35. Clear&Simple: Developing effective print materials for low-literate readers. Bethesda (MD): National Cancer Institute, 1994. [http://oc.nci.nih.gov/services/Clear\\_and\\_Simple](http://oc.nci.nih.gov/services/Clear_and_Simple)
36. Crystal D. *The Cambridge Encyclopedia of Language*. Cambridge University Press, Cambridge, 1997.
37. Davis M. *Scientific papers and presentations*. Academic Press, London, 1997.
38. Pfizer Clear Health Communication Initiative. <http://www.pfizerhealthliteracy.com>
39. The Federal Government's Plain Language Initiative. <http://www.plainlanguage.gov>
40. Flesch R. *The art of readable writing*. Harpers & Brothers Publishers, New York 1949.
41. Wycliffe Associates: *Easy English*. [www.easyenglish.info](http://www.easyenglish.info)

42. Plain English Campaign. <http://www.plainenglish.co.uk>
43. Doctor-patient interaction and communication. World Health Organization, Geneva 1993.
44. Literacy Skills Are Strongest Predictor of Health Status in United States; New Coalition Unveils Action Agenda, Tools to Elevate 'Health Literacy' Among At-Risk Populations. Prema: Partnership for Clear Health Communication.  
<http://www.highbeam.com/doc/1G1-101279511.html>; <http://npsf.org/askme3/PCHC>
45. Eagle L, Hawkins J, Styles E, Reid J. Breaking through the invisible barrier of low functional health literacy: implications for health communication. *Studies in Communication Sciences, Special Issue on Health Literacy* 2006;5(2):29-55.
46. Baker DW, Parker RM, Williams MV, Clark WS, Nurss J. The relationship of patient reading ability to self-reported health and use of health services. *American Journal of Public Health* 1997;87(6):1027-1030.
47. Baker DW, Parker RM, Williams MV, Clark WS. Health literacy and the risk of hospital admission. *Journal of General Internal Medicine* 1998;13(12):791-798.
48. Scott TL, Gazmararian JA, Williams MV, Baker DW. Health literacy and preventive health care use among Medicare enrollees in a managed care organization. *Medical Care* 2002;40:395-404.
49. Schillinger D, Grumbach K, Piette J, Wang F, Osmond D, Daher C, et al. Association of health literacy with diabetes outcomes. *JAMA* 2002;288(4):475-482.
50. Schillinger D. Improving chronic disease care for populations with limited health literacy. U: Nielsen-Bohlman L i sur. (ur.): Health literacy: a prescription to end confusion. Institute of Medicine, The National Academies Press, Washington, 2004., str. 267-284.
51. Shea JA, Guerra CE, Ravenell KL, McDonald VJ, Henry CAM, Asch DA. Health literacy weakly but consistently predicts primary care patient dissatisfaction. *International Journal for Quality in Health Care* 2007;19(1):45-49.
52. Nutbeam D. Health literacy as a public health goal: a challenge for contemporary health education and communication strategies into the 21<sup>st</sup> century. *Health Promotion International* 2000;15(3):259-67.
53. Ratzan SC, Parker RM. Introduction - Health literacy (bibliography online). Bethesda, MD: National Library of Medicine, 2000. <http://www.nlm.nih.gov/pubs/resources.html>
54. Health literacy: report of the Council on Scientific Affairs. Ad Hoc Committee on Health Literacy for the Council on Scientific Affairs, American Medical Association. *JAMA* 1999;281:552-557.
55. Zarkadoolas C, Pleasant A, Greer DS. Understanding health literacy: an expanded model. *Health Promotion International* 2005;20(2):195-203.
56. Osborne H. Health literacy from A to Z: Practical ways to communicate your health message. Jones and Bartlett Publishers, Sudbury, 2005.

57. Parker RM, Baker DW, Williams MV, Nurss JR. The test of functional health literacy in adults: a new instrument for measuring patient's literacy skills. *Journal of General Internal Medicine* 1995;10:537-41.
58. Doak CC, Doak LG, Root JH. Teaching patients with low literacy skills. J. B. Lippincott Company (2. izd.), Philadelphia 1996.
59. Nielsen-Bohlman L i sur. (ur.): Health literacy: a prescription to end confusion. Institute of Medicine, The National Academies Press, Washington, 2004.
60. Albert T. Written information for patients. *Lancet* 2000;356:434.
61. Graber MA, Roller CM, Kaeble B. Readability Levels of Patient Education Material on the World Wide Web. *J Fam Pract* 1999;48(1):58-61.
62. Davis TC, Crouch MA, Wills G, Miller S, Abdehou DM. The gap between patient reading comprehension and the readability of patient education materials. *Journal of Family Practice* 1990;31:533-538.
63. Kusec S, Brborovic O, Schillinger D. Diabetes websites accredited by the Health On the Net Foundation Code of Conduct: readable or not?. *Studies in Health Technology & Informatics*. 2003;95:655-60.
64. Kusec S, Mastilica M, Pavlekovic G, Kovacic L. Readability of Patient Information on Diabetes on the Croatian Web Sites. In: G Surjan et al., eds. *Medical Informatics Europe 2002*. IOS Press 2002;128-132.
65. Mathews PJ et al. The Use of Readability Formulas in Patient Education Materials. American Association for Respiratory Therapy Summer Forum, Reno, NV, July 26-28, 1985.
66. Smith H, Gooding S, Brown R, Frew A. Evaluation of Readability and Accuracy of Information Leaflets in General Practice for Patients with Asthma. *BMJ* 1998;317:264-265.
67. Zakon o zdravstvenoj zaštiti i zdravstvenom osiguranju. Narodne novine, 1993.
68. Zakon o zaštiti prava pacijenata. Narodne novine br.169/04, 2004.
69. Državni zavod za statistiku. Statistički ljetopis 2003. (Statistical Yearbook). Zagreb: Državni zavod za statistiku, 2003.
70. Petriček G, Vrcić-Keglević M, Vuletić G, Cerovečki V, Ožvačić Z, Murgić L. Illness perception and cardiovascular risk factors in patients with type 2 diabetes: cross-sectional questionnaire study. *Croat Med J* 2009;50:583-93.
71. Državni zavod za statistiku. Statistički ljetopis 2003. (Statistical Yearbook). Zagreb: Državni zavod za statistiku, 2003.
72. Parikh NS, et al. Shame and health literacy: the unspoken connection. *Patient Education and Counseling* 1996;27:33-39.

73. Davis TC, Michielutte R, Askov EN, Williams MV, Weiss BD. Practical assessment of adult literacy in health care. *Health Education and Behaviour* 1998;25(5):613-624.
74. Maag D. Health literacy – compendium of prior research. *Studies in Communication Sciences* 2005;5(2):11-28.
75. Nurss JR, Baker D, Davis T, Parker R, Williams M. Difficulty in functional health literacy screening in Spanish-speaking adults. *Journal of Reading* 1995;38:632-637.
76. Taylor WL. “Cloze procedure”: a new tool for measuring readability. *Journalism Q* 1953;30:415-33.
77. Baker DW, Williams MV, Parker RM, Gazmararian JA, Nurss J. Development of a brief test to measure functional health literacy. *Patient Educ Couns* 1999;38:33-42.
78. Epel OB, Balin L, Daniely Z, Eidelman S. Validation of a Hebrew health literacy test. *Patient Educ Couns* 2007;67:235-239.
79. Alderson JC. *Assessing Reading*. Cambridge Language Assessment Series. Cambridge University Press, Cambridge 2000.
80. Thorndike RL. *Reading as reasoning*. American Psychological Association, Washington, DC, 1917.
81. Goodman KS. *Process, theory, research*. Routledge and Kegan Paul. London, 1882.
82. Smith F. *Understanding reading*. Holt, Rinehart and Winston, New York, 1971.
83. Fuchs LS, Fuchs D, Hosp MK, Jenkins JR. Oral reading fluency as an indicator of reading competence: a theoretical, empirical, and historical analysis. *Scientific Studies in Reading* 2001;5(3):241-258.
84. Carver RP. Optimal rate of reading prose. *Reading Research Quarterly* 1982;18(1):56-88.
85. Laufer B. What percentage of text-lexis is essential for comprehension? U: Lauren C, Musumeci D (ur.). *Special language: from humans thinking to thinking machines*. Multilingual Matters, Philadelphia, 1989.
86. Liu N, Nation ISP. Factors affecting guessing vocabulary in context. *RELJ Journal* 1985;16(1):33-42.
87. HirshD, Nation P. What vocabulary size is needed to read unsimplified texts for pleasure? *Reading in a Foreign language* 1992;8(2):689-696.
88. Chall JS. *Readability – an appraisal of research and application*. Columbus, OH: Bureau of Educational Research, Ohio State University, 1958.
89. Harrison C. *Assessing the readability of school texts*. U: Lunzer E, Gardner K (ur.). *The effective use of reading*. Heinemann, London, 1979.
90. DuBay WH. *The principles of readability*. Impact Information, Costa Mesa, California, 2004.

91. Klare GR. The measurement of readability. Iowa State University Press, Ames, Iowa, 1963.
92. Hargis G, Hernandez AK, Hughes P, Ramaker J, Rouiller S, Wilde E. Developing quality technical information: a handbook for writers and editors. Prentice Hall, Upper Saddle River, NJ, 1998.
93. Rabin AT. Determining difficulty levels of text written in languages other than English. U: Zakaluk BL, Samuels SJ (ur.): Readability: Its past, present, and future. International Reading Association, Newark, 1988., str. 46-76.
94. Contreras A, Garcia-Alonso R, Echenique M, Daye-Contreras F. The SOL formulas for converting SMOG readability scores between health education materials written in Spanish, English, and French. *J Health Commun* 1999;4(1):21-9.
95. Daglio MM, Fattori G, Ciardullo AV. Assessment of readability and learning of easy-to-read educational health materials designed and written with the help of citizens by means of two non-alternative methods. *Advances in Health Sciences Education* 2006;11:123-132.
96. McCall WA, Crabbs LM. Standard test lessons in reading. New York: Teachers College, Columbia University Press; 1926.
97. Sherman AL. Analytics of literature: a manual for the objective study of English prose and poetry. Boston: Ginn & Co., 1893.
98. Chall JS, Dale E. Readability revisited, the new Dale-Chall readability formula. Brookline Books, Cambridge, MA, 1995.
99. Johnson W. People in quandaries. New York: Harpers; 1946.
100. Fry EB, Kress JE, Fountoukidis DL. The reading teacher's book of lists. 3.izd. West Nyack, New York: The centre for applied research in education; 1993.
101. Zipf GK. Human behavior and the principle of least effort: an introduction to human ecology. New York: Addison-Wesley, 1949.
102. Klare GR. The role of word frequency in readability. *Elementary English* 1968;45:12-22.
103. Lively BA, Pressey SL. A method for measuring the vocabulary burden of textbooks. *Educational Administration and Supervision* 1921;9:398-98.
104. Vogel M, Washburne C. An objective method of determining grade placement of children's reading material. *Elementary School Journal* 1928;28:373-81.
105. Gray WS, Leary B. What makes a book readable. Chicago: Chicago University Press; 1935.
106. Flesch R. The art of readable writing. Harpers & Brothers Publishers, New York 1949.
107. Flesch R. Marks of a readable style. Columbia University contributions to education, no. 897. Bureau of Publications, Teachers College, Columbia University, New York, 1943.



108. Klare GR. The formative years. U: Zakaluk BL, Samuels SJ (ur.): Readability: Its past, present, and future. International Reading Association, Newark, 1988.
109. Smith S. Readability Testing Health Information (1998). <http://www.prenataled.com>.
110. Kincaid JP, Fishburne RP, Rogers RL, Chissom BS. Derivation of new readability formulas (Automated Readability Index, Fog Count and Flesch Reading Ease Formula) for Navy enlisted personnel, Research Branch Report 8-75, Millington, TN: Naval Technical Training, U. S. Naval Air Station, Memphis, 1975.
111. McLaughlin GH. SMOG grading – a new readability formula. *J Reading* 1969;12:639-46.
112. McCall WA, Crabbs LM. Standard test lessons in reading. New York: Teachers College, Columbia University Press; 1961.
113. Gunning R. The technique of clear writing. New York: McGraw-Hill, 1952.
114. McLaughlin GH. What makes prose understandable. University College London; disertacija, 1966.
115. Readability. Wikipedia, the free encyclopedia. [www.wikipedia.com](http://www.wikipedia.com)
116. Fry E. A readability formula that saves time. *Journal of Reading* 1968;11:513–516.
117. Dale E, Chall JS. A formula for predicting readability. *Educational Research Bulletin* 1948;27:1-20, 37-54.
118. Caylor JS, Sticht TG, Fox LC, Ford JP. Methodologies for determining reading requirements of military occupational specialties. Technical Report No. 73-5. Human Resources Research Organization, Alexandria, 1973.
119. Franchina V, Vacca R. Adaptation of Flesch readability index on a bilingual text written by the same author both in Italian and English languages. *Linguaggi* 1986;3:47-49.
120. Daghigho MM, Fattori G, Ciardullo AV. Assessment of readability and learning of easy-to-read educational health materials designed and written with the help of citizens by means of two non-alternative methods. *Advances in Health Sciences Education* 2006;11:123-132.
121. W3C Office in Italy. [www.W3c.it](http://www.W3c.it)
122. Lucisano P, Piemontese M.E. GulpEase: a formula to predict readability of texts written in Italian language. U: School and Town. La Nuova Italia, Brescia, 1988, str. 3-31.
123. Indice GulpEase: scala dei valori. [www.eulogos.net](http://www.eulogos.net)
124. Björnsson CH. Läsbarhet. Liber, Lund, 1968.
125. Nilsson K, Borin L. Living off the land: the web as a source of practice texts for learners of less prevalent languages. Proceedings LREC – Third international conference on language resources and evaluation, Vol. II, Las Palmas, Spain, 2002, str. 411-418.
126. LIX-kalkylator. [www.pressylta.com/lix](http://www.pressylta.com/lix)
127. Jakobsen G. (ur.) Dansk Lix 70. Laesepædagogien, 1971.

128. Douma WH. De Leesbaarheid van Landbouwbladen: een Onderzoek naar en een Toepassing van Leesbaarheidsformules. Bulletin No. 17. Sociologie en Sociographie. Landbouwhogeschool te Wageningen, Netherlands, 1960.
129. Kandel L, Moles A. Application de l'indice de Flesch à la langue française. Cahiers d'Etudes de Radio Télévision 1958;19:253-274.
130. Fernández Huerta J. Medidas sencillas de lecturabilidad. Consigna 1959;214:29-32.
131. Manzo A. Readability: a postscript. Elementary English 1970;47:962-965.
132. Maxwell M. Readability: have we gone too far? Journal of Reading 1978;21:525-530.
133. Selzer J. Readability is a four-letter word. Journal of Business Communication 1981;18(4):23-34.
134. Bruce B, Rubin A, Starr K. Why readability formulas fail. Reading Education Report No. 28. Champaign, University of Illinois at Urbana-Champaign, 1981.
135. Lange R. Readability formulas: Second looks, second thoughts. Reading Teacher 1982;35:858-961.
136. Duffy TM. Readability formulas: what's the use? U: Duffy TM, Waller RM (ur.). Designing usable texts. Academic Press, New York, 1985, str. 113-143.
137. Connaster BF. Last rites for readability formula sin technical communication. Journal of Technical Writing and Communication 1999;24(3):271-287.
138. Ojemann R. The reading ability of parents and factors associated with the reading difficulty of parent education materials. U: Stoddard GD. Researchers in Parent Education II, University of Iowa, Iowa City, 1934.
139. Klare GR, Rowe PP, St. John MG, Stolurow LM. Automation of the Flesch reading ease readability formula, with various options. Reading Research Quarterly 1969;4(4):550-559.
140. Kintsch W, Vipond E. Reading comprehension and readability in educational practice and psychological theory. U: Nilsson LG (ur.). Perspectives on memory research, Erbaum, Hillsdale, 1979.
141. Kintsch W, Miller JR. Readability: a view from cognitive psychology. U: Teaching: Research reviews. International Reading Association, Neward, 1981.
142. Redish JC, Selzer J. The place of readability formulas in technical communication. Technical Communication 1985;32(4):46-52.
143. Schriver K. Readability formulas in the new millennium: what's the use? ACM Journal of Computer Documentation 2000;24(3):138-140.
144. Hunt K. Grammatical structures written at three grade levels. National council of Teachers of English Report No.3. National Council of Teachers of English, Urbana, 1965.
145. Bormuth JR. Readability: a new approach. Reading Research Quarterly 1966;1:79-132.

146. Coupland N. Is readability real? *Communication of Scientific and Technical Information* 1978;15-17.
147. Chall JS. Readability and prose comprehension: continuities and discontinuities. U: Flood J. (ur.) *Understanding reading comprehension: cognition, language, and the structure of prose*. International Reading Association, Newark, 1984.
148. Klare GR. Readability. U: Pearson PD (ur.). *Handbook of Reading Research*, Longman, New York, 1984, str. 681-744.
149. Davison A. Readability formulas and comprehension. U: Duffy GG, Roehler LR, Mason J (ur.). *Comprehension instruction: perspectives and suggestions*. Longman, New York, 1984.
150. Davison A. Readability: the situation today. *Reading Education Report No. 70*. University of Illinois at Urbana-Champaign, Center for the Study of Reading, Champaign, 1986.
151. Carver RP. Predicting accuracy of comprehension from the relative difficulty of material. *Learning and Individual Differences* 1990;2:405-422.
152. Chall JS, Conard SS. Should textbooks challenge students? The case for easier or harder textbooks. Teachers College Press, New York, 1991.
153. Coleman EB. Improving comprehensibility by shortening sentences. *Journal of Applied Psychology* 1962;46:131.
154. SETimes – South Eastern European Times. [www.setimes.com](http://www.setimes.com)
155. Words Count Readability. [www.wordscount.info/wc/clear/analyze\\_readability.jsp](http://www.wordscount.info/wc/clear/analyze_readability.jsp)
156. Text Content Analysis Tool. [www.usingenglish.com](http://www.usingenglish.com)
157. Kušec S. Usklađivanje profesionalne i laičke terminologije u odnosu liječnik-pacijent. Magistarski rad, Zagreb, 2005.
158. McLaughlin GH. Temptations of the Flesch. *Instructional Science* 1974;2:367-384.
159. Kušec S, Orešković S, Škegrov M, Korolija D, Bušić Ž, Horžić M. Improving comprehension of informed consent. *Patient Educ Couns* 2006;60:294-300.
160. Payne S, Large S, Jarrett N, Turner P. Written information given to patients and families by palliative care units: a national survey. *Lancet* 2000;355(9217):1792.
161. King MM, Winton ASW, Adkins AD. Assessing the readability of mental health internet brochures for children and adolescents. *Journal Child & Family Studies* 2003;12(1):91-100.
162. Alexander RE. Readability of published dental educational materials. *Journal American Dental Association* 2000;7:937-943.
163. Harvey HD, Fleming P. The readability and audience acceptance of printed health promotion materials used by environmental health departments. *Journal Environmental Health* 2003;65(6):22-29.

164. Williams BF, French JK, White HD. Informed consent during the clinical emergency of acute myocardial infarction (HERO-2 consent substudy): a prospective observational study. *Lancet* 2003;361(9361):918-923.
165. Hochhauser M. The effects of HIPAA on research consent forms. *Patient Care Management* 2002;17(5):6-7.
166. Matthew J. Readability of consent forms in schizophrenia research. *Australian and New Zealand Journal Psychiatry* 2002;36(4):564-566.
167. Paasche-Orlow MK, Taylor HA, Brancati FL. Readability standards for informed consent forms as compared with actual readability. *New England Journal Medicine* 2003;248(8):721-727.
168. Oermann MH, Wilson FE. Quality of health care information for consumers on the internet. *Journal Nursing Care Quality* 2000;14(4):45-55.
169. Weeks WB, Wallace AE. Readability of British and American medical prose at the start of the 21st century. *Brit Med J* 2002;325(7378):1451-1453.
170. Freedman DA, Bess KD, Tucker HA, Boyd DL, Tuchman AM, Wallston KA. Public health literacy defined. *Am J Prev Med* 2009;36(5):446-451.
171. Nelson JC, Schwartzberg JG, Vergara KC. The public's and the patient's right to know: AMA commentary on „Public health literacy in America: an ethical imperative“. *Am J Prev Med* 2005;28(3):325-326.

## 10. ŽIVOTOPIS

Mr. sc. Sanja Brangan, prof. (rođena Kušec) rođena je 22. listopada 1964. godine u Bjelovaru. Djetinjstvo provodi u Čazmi, gdje završava osnovnu školu, a srednju školu završava u Zagrebu, u Obrazovnom centru za jezike. Diplomira 1990. godine na Filozofskom fakultetu Sveučilišta u Zagrebu, dvopredmetni studij engleskog jezika i književnosti i talijanskog jezika i književnosti. Zapošljavanjem na Školi narodnog zdravlja “Andrija Štampar” Medicinskog fakulteta Sveučilišta u Zagrebu, na radnom mjestu prevoditelja za engleski jezik, usmjerava se na područje javnog zdravstva te završetkom poslijediplomskog studija iz javnog zdravstva na Medicinskom fakultetu Sveučilišta u Zagrebu stječe titulu magistra znanosti. Baveći se primijenjenim istraživanjima jezika, prevođenja i komunikacije u području medicine i zdravstva, objavljuje radove iz tog područja te ih prezentira na državnim i međunarodnim znanstvenim skupovima u organizaciji Europskog udruženja za komunikaciju u zdravstvu (“European Association for Communication in Healthcare”), Hrvatskog društva za primijenjenu lingvistiku, Hrvatskog udruženja profesora engleskog jezika te na konferencijama Medical Informatics Europe. Recenzent je časopisa Patient Education and Counseling, PLoS ONE i Surgical Laparoscopy, Endoscopy & Percutaneous Techniques. Aktivno je sudjelovala u znanstvenim projektima „Hipermedija u medinskoj edukaciji“ i „Znanstveni temelji kvalitete zdravstvene zaštite“, trenutno u znanstvenom projektu “Izrada modela i instrumenta za ocjenu zdravstvene pismenosti u Hrvatskoj” i projektima lingvističke validacije upitnika za pacijente. Sudjeluje u nastavi iz kolegija Medicinska sociologija te Medicinski engleski, ali i na poslijediplomskom znanstvenom studiju iz biomedicine na Medicinskom fakultetu u seminaru “Language and style of scientific writing” unutar kolegija “Struktura, metodika i funkcioniranje znanstvenog rada”.

## 11. PRILOZI

### 11.1. PRILOG 1: Popis tekstova na engleskom jeziku – uzorak od 90 odlomaka

#### Knjige:

1. J.K. Rowling: Harry Potter and the chamber of secrets. Scholastic Inc., New York, 2000. pp.1-3. (B)
2. J.K. Rowling: Harry Potter and the chamber of secrets. Scholastic Inc., New York, 2000. pp.169-170. (M)
3. J.K. Rowling: Harry Potter and the chamber of secrets. Scholastic Inc., New York, 2000. pp.340-341. (E)
4. Robin Cook: Abduction. The Berkley Publishing Group, New York, 2000. pp.1-2. (B)
5. Robin Cook: Abduction. The Berkley Publishing Group, New York, 2000. pp.200-201. (M)
6. Robin Cook: Abduction. The Berkley Publishing Group, New York, 2000. pp.401-402. (E)
7. Robin Cook: Seizure. Pan MacMillan, London, 2003. pp.1-3. (B)
8. Robin Cook: Seizure. Pan MacMillan, London, 2003. pp.268-270. (M)
9. Robin Cook: Seizure. Pan MacMillan, London, 2003. pp.542-543. (E)
10. Robin Cook: Shock. The Berkley Publishing Group, New York, 2001. pp.5-6. (B)
11. Robin Cook: Shock. The Berkley Publishing Group, New York, 2001. pp.166. (M)
12. Robin Cook: Shock. The Berkley Publishing Group, New York, 2001. pp.337. (E)
13. Dan Brown: Angels and demons. Transworld Publishers, London, 2001. pp.19-20. (B)
14. Dan Brown: Angels and demons. Transworld Publishers, London, 2001. pp.304-305. (M)
15. Dan Brown: Angels and demons. Transworld Publishers, London, 2001. pp.619-620. (E)
16. Dan Brown: Digital fortress. Transworld Publishers, London, 2004. pp.12-13. (B)
17. Dan Brown: Digital fortress. Transworld Publishers, London, 2004. pp.250-251. (M)
18. Dan Brown: Digital fortress. Transworld Publishers, London, 2004. pp.509. (E)
19. Stephen King: Rose Madder. Penguin Books, New York, 1995. pp.15-13. (B)
20. Stephen King: Rose Madder. Penguin Books, New York, 1995. pp.232-233. (M)
21. Stephen King: Rose Madder. Penguin Books, New York, 1995. pp.465-466. (E)
22. Michael Crichton: Timeline. Random House, London, 1999. pp.3-4. (B)
23. Michael Crichton: Timeline. Random House, London, 1999. pp.241-242. (M)
24. Michael Crichton: Timeline. Random House, London, 1999. pp.484-485. (E)
25. Dean Koontz: Intensity. Ballantine Books, New York, 1996. pp.1-3. (B)
26. Dean Koontz: Intensity. Ballantine Books, New York, 1996. pp.214-216. (M)
27. Dean Koontz: Intensity. Ballantine Books, New York, 1996. pp.435-436. (E)
28. David Lodge: Thinks. Penguin Books, London, 2002. pp.10-11. (B)
29. David Lodge: Thinks. Penguin Books, London, 2002. pp.191-192. (M)
30. David Lodge: Thinks. Penguin Books, London, 2002. pp.10-11. (B)
31. John Grisham: The firm. The Random House, London, 1991. pp. 1.-2. (B)
32. John Grisham: The firm. The Random House, London, 1991. pp. 489.-490. (E)
33. John Grisham: The firm. The Random House, London, 1991. pp. 489.-490. (E)

#### SETimes:

34. Muhamet Brajshori: *Kosovo's Roma: life on the streets*. SETimes, 27.12.2010.
35. Natasa Radic: Turkish soap opera attracts regional audience. SETimes, 20.12.2010.

36. Svetla Dimitrova: Jewel losing its lustre: pollution plagues Black Sea. SETimes, 18.10.2010.
37. Igor Jovanovic: *Belgrade's footballmania*. SETimes, 14.6.2010.
38. Linda Karadaku: Kosovo: money from abroad critical when the cupboard is bare. SETimes, 26.4.2010.
39. Natasa Radic: Stjepan Mesic ends a decade in power. SETimes, 18.1.2010.
40. (Various sources): Balkan issues will keep International Court of Justice busy. SETimes, 22.12.2008.
41. Ayhan Simsek: Newborn deaths spark debate on Turkey's health system. SETimes, 6.10.2008.
42. Natasa Radic: Croatia may leave Non-Aligned Movement. SETimes, 11.08.2008.
43. Natasa Radic: Summer in the Balkans means sea and sun. SETimes, 9.6.2008.
44. Nedjeljko Rudovic: Montenegro balks at opening up real estate market. SETimes, 28.4.2008.
45. Sami Neza: Albania 2008, forecasts and challenges. SETimes, 18.2.2008.
46. Daniel Daianu: News mostly good for Romanian economy. SETimes, 30.10.2006.
47. Georgi Mitev-Shantek: *Balkan biofuel could be on the horizon*. SETimes, 21.08.2006.
48. Igor Jovanovic: Visa issue makes for common cause in the Western Balkans. SETimes, 05.06.2006.
49. Davor Konjikusic: Recovery under way in Serbia after floods. SETimes, 22.05.2006.
50. Antonela Arhin: Progress in Serbia-Montenegro's Defence Reform. SETimes, 13.02.2006.
51. Daniel Daianu: Oil prices, emerging economies reshape global picture. SETimes, 03.01.2006.
52. Dusan Kosanovic: Basketball Brings Together Former Yugoslav Republics. SETimes, 14.11.2004.
53. Beth Kampschorr: Former Yugoslav Countries Beginning to Address War Crimes in Local Courts. SETimes, 11.10.2004.
54. Zoran Nikolovski: Amid signals of economic recovery, Macedonians await a better life. SETimes, 24.10.2005.
55. Daniel Daianu: EU Referenda Complicate Accession Prospects. SETimes, 04.07.2005.
56. Svetla Dimitrova: Report Highlights Gender Equality Problems in Eastern Europe. SETimes, 16.05.2005.
57. Davor Konjukusic: *Two Years of the Constitutional Charter*. SETimes, 07.03.2005.

Znanstveno-popularni tekstovi:

58. Bryan Sykes: *The seven daughters of Eve*. Transworld Publishers, London, 2002. pp.17-21. (B)
59. Bryan Sykes: *The seven daughters of Eve*. Transworld Publishers, London, 2002. pp.181-184. (M)
60. Bryan Sykes: *The seven daughters of Eve*. Transworld Publishers, London, 2002. pp.358-360. (E)
61. Richard Dawkins: *The selfish gene*. Oxford University Press, Oxford, 1989. pp.1-2. (B)
62. Richard Dawkins: *The selfish gene*. Oxford University Press, Oxford, 1989. pp.164-165. (M)
63. Richard Dawkins: *The selfish gene*. Oxford University Press, Oxford, 1989. pp.264-266. (E)
64. Bill Bryson: *A short history of nearly everything*. Transworld Publishers, London, 2004. pp.27-28. (B)
65. Bill Bryson: *A short history of nearly everything*. Transworld Publishers, London, 2004. pp.298-300. (M)

66. Bill Bryson: A short history of nearly everything. Transworld Publishers, London, 2004. pp.572-574. (E)
67. Steve Jones: Y: The descent of men. Little, Brown Book Group, London, 2002. str.11-13. (B)
68. Steve Jones: Y: The descent of men. Little, Brown Book Group, London, 2002. str.129-130. (M)
69. Steve Jones: Y: The descent of men. Little, Brown Book Group, London, 2002. str.258-260. (E)
70. Misha Glenny: McMafia: A journey through the global criminal underworld. Random House, New York, 2008. str.3-5. (B)
71. Misha Glenny: McMafia: A journey through the global criminal underworld. Random House, New York, 2008. str.175-177. (M)
72. Misha Glenny: McMafia: A journey through the global criminal underworld. Random House, New York, 2008. str.343-346. (E)
73. Stephen Hawking: The illustrated a brief history of time. Bantam Press, London, 1996. pp.2-5. (B)
74. Stephen Hawking: The illustrated a brief history of time. Bantam Press, London, 1996. pp.118-120. (M)
75. Stephen Hawking: The illustrated a brief history of time. Bantam Press, London, 1996. pp.236-239. (E)

JAMA-HR:

76. Fitzgibbons RJ, Giobbie-Hurder A, Gibbs JO, et al. Watchful waiting vs repair of inguinal hernia in minimally symptomatic men: a randomized clinical trial. JAMA 2006;295:285-292. (B)
77. Fitzgibbons RJ, Giobbie-Hurder A, Gibbs JO, et al. Watchful waiting vs repair of inguinal hernia in minimally symptomatic men: a randomized clinical trial. JAMA 2006;295:285-292. (M)
78. Fitzgibbons RJ, Giobbie-Hurder A, Gibbs JO, et al. Watchful waiting vs repair of inguinal hernia in minimally symptomatic men: a randomized clinical trial. JAMA 2006;295:285-292. (E)
79. Walsh JME, Pignone M. Drug treatment of hyperlipidemia in women. JAMA 2004;291:2243-2252. (B)
80. Walsh JME, Pignone M. Drug treatment of hyperlipidemia in women. JAMA 2004;291:2243-2252. (M)
81. Walsh JME, Pignone M. Drug treatment of hyperlipidemia in women. JAMA 2004;291:2243-2252. (E)
82. van Walraven C, Hart RG, Singer DE, et al. Oral anticoagulants vs aspirin in nonvalvular atrial fibrillation. JAMA 2002;288:2441-2448. (B)
83. van Walraven C, Hart RG, Singer DE, et al. Oral anticoagulants vs aspirin in nonvalvular atrial fibrillation. JAMA 2002;288:2441-2448. (M)
84. van Walraven C, Hart RG, Singer DE, et al. Oral anticoagulants vs aspirin in nonvalvular atrial fibrillation. JAMA 2002;288:2441-2448. (E)
85. Piccirillo JF, Mager DE, Frisse ME, et al. Impact of first-line vs second-line antibiotics for the treatment of acute uncomplicated sinusitis. JAMA 2001;286:1849-1856. (B)
86. Piccirillo JF, Mager DE, Frisse ME, et al. Impact of first-line vs second-line antibiotics for the treatment of acute uncomplicated sinusitis. JAMA 2001;286:1849-1856. (M)
87. Piccirillo JF, Mager DE, Frisse ME, et al. Impact of first-line vs second-line antibiotics for the treatment of acute uncomplicated sinusitis. JAMA 2001;286:1849-1856. (E)



88. Lipton RB, Stewart WF, Stone AM, et al. Stratified care vs step care strategies for migraine. The Disability in Strategies of Care (DISC) Study: A randomized trial. JAMA 2000;284:2599-2605. (B)
89. Lipton RB, Stewart WF, Stone AM, et al. Stratified care vs step care strategies for migraine. The Disability in Strategies of Care (DISC) Study: A randomized trial. JAMA 2000;284:2599-2605. (M)
90. Lipton RB, Stewart WF, Stone AM, et al. Stratified care vs step care strategies for migraine. The Disability in Strategies of Care (DISC) Study: A randomized trial. JAMA 2000;284:2599-2605. (E)

## 11.2. PRILOG 2: Popis tekstova na hrvatskom jeziku – uзорak od 90 odlomaka

### Knjige:

1. J.K. Rowling: Harry Potter i odaja tajni. Algoritam, Zagreb, 2002. str.7-8. (B) (prijevod: Zlatko Crnković)
2. J.K. Rowling: Harry Potter i odaja tajni. Algoritam, Zagreb, 2002. str.136-137. (M) (prijevod: Zlatko Crnković)
3. J.K. Rowling: Harry Potter i odaja tajni. Algoritam, Zagreb, 2002. str.269-270. (E) (prijevod: Zlatko Crnković)
4. Robin Cook: Otmica. Leo Commerce, Rijeka, 2001. str.7-8. (B) (prijevod: Vesna Valenčić)
5. Robin Cook: Otmica. Leo Commerce, Rijeka, 2001. str.184-185. (M) (prijevod: Vesna Valenčić)
6. Robin Cook: Otmica. Leo Commerce, Rijeka, 2001. str.364-365. (E) (prijevod: Vesna Valenčić)
7. Robin Cook: Napadaj. Leo Commerce, Rijeka, 2004. str.5-7. (B) (prijevod: Vesna Valenčić)
8. Robin Cook: Napadaj. Leo Commerce, Rijeka, 2004. str.238-239. (M) (prijevod: Vesna Valenčić)
9. Robin Cook: Napadaj. Leo Commerce, Rijeka, 2004. str.474-475. (E) (prijevod: Vesna Valenčić)
10. Robin Cook: Šok. Leo Commerce, Rijeka, 2002. str.9-10. (B) (prijevod: Vesna Valenčić)
11. Robin Cook: Šok. Leo Commerce, Rijeka, 2002. str.174-175. (M) (prijevod: Vesna Valenčić)
12. Robin Cook: Šok. Leo Commerce, Rijeka, 2002. str.351. (E) (prijevod: Vesna Valenčić)
13. Dan Brown: Anđeli i demoni. VBZ, Zagreb, 2004. str. 15. (B) (prijevod: Suzana Sesvečan)
14. Dan Brown: Anđeli i demoni. VBZ, Zagreb, 2004. str. 230. (M) (prijevod: Suzana Sesvečan)
15. Dan Brown: Anđeli i demoni. VBZ, Zagreb, 2004. str. 462-463. (E) (prijevod: Suzana Sesvečan)
16. Dan Brown: Digitalna tvrđava. Delfin, Zagreb, 2004. str. 11. (B) (prijevod: Kristina Turkalj)
17. Dan Brown: Digitalna tvrđava. Delfin, Zagreb, 2004. str. 204. (M) (prijevod: Kristina Turkalj)
18. Dan Brown: Digitalna tvrđava. Delfin, Zagreb, 2004. str. 407-408. (E) (prijevod: Kristina Turkalj)
19. Stephen King: Rose Madder. Algoritam, Zagreb, 1996. str. 11-12. (B) (prijevod: Božica Jakovlev)
20. Stephen King: Rose Madder. Algoritam, Zagreb, 1996. str. 242-243. (M) (prijevod: Božica Jakovlev)
21. Stephen King: Rose Madder. Algoritam, Zagreb, 1996. str. 492-493. (B) (prijevod: Božica Jakovlev)
22. Michael Crichton: Niz vrijeme. Algoritam, Zagreb, 2001. str. 15-16. (B) (prijevod: Gordana Mijatović)
23. Michael Crichton: Niz vrijeme. Algoritam, Zagreb, 2001. str. 263-264. (M) (prijevod: Gordana Mijatović)
24. Michael Crichton: Niz vrijeme. Algoritam, Zagreb, 2001. str. 520-521. (E) (prijevod: Gordana Mijatović)
25. Dean Koontz: Žestina. SysPrint, Zagreb, 2001. str.11-12. (B) (prijevod: Predrag Raos)
26. Dean Koontz: Žestina. SysPrint, Zagreb, 2001. str. 126-127. (M) (prijevod: Predrag Raos)
27. Dean Koontz: Žestina. SysPrint, Zagreb, 2001. str.245. (E) (prijevod: Predrag Raos)
28. David Lodge: Misli. Vuković & Runjić, Zagreb, 2005. str.18-19. (B) (prijevod: Maja Tančik)

29. David Lodge: Misli. Vuković & Runjić, Zagreb, 2005. str.199-200. (M) (prijevod: Maja Tančik)
30. David Lodge: Misli. Vuković & Runjić, Zagreb, 2005. str.350-351. (E) (prijevod: Maja Tančik)
31. John Grisham: Tvrтка. Algoritam, Zagreb, 2004. str.5-6. (B) (prijevod: Predrag Raos)
32. John Grisham: Tvrтка. Algoritam, Zagreb, 2004. str. 227. (M) (prijevod: Predrag Raos)
33. John Grisham: Tvrтка. Algoritam, Zagreb, 2004. str.447. (E) (prijevod: Predrag Raos)

#### SETimes:

34. Muhamet Brajšhori: *Kosovski Romi: život na ulicama*. SETimes, 27.12.2010.
35. Nataša Radić: Turska sapunica privlači publiku iz regije. SETimes, 20.12.2010.
36. Svetla Dimitrova: Dragulj koji gubi sjaj: zagađenje ugrožava Crno more. SETimes, 18.10.2010.
37. Igor Jovanović: *Nogometna manija u Beogradu*. SETimes, 14.6.2010.
38. Linda Karadaku: Kosovo: novac iz inozemstva presudan je kad ponestane namirnica. SETimes, 26.4.2010.
39. Nataša Radić: Stjepan Mesić okončao desetljeće na vlasti. SETimes, 18.1.2010.
40. (Razni izvori): Međunarodni sud pravde imat će pune ruke posla s balkanskim pitanjima. SETimes, 22.12.2008.
41. Ayhan Simsek: Smrti novorođenčadi potakle debatu o zdravstvenom sustavu u Turskoj. SETimes, 6.10.2008.
42. Nataša Radić: Hrvatska bi mogla napustiti pokret nesvrstanih. SETimes, 11.08.2008.
43. Nataša Radić: Ljeto na Balkanu znači more i sunce. SETimes, 9.6.2008.
44. Nedjeljko Rudović: Crna Gora blokira otvaranje tržišta nekretnina. SETimes, 28.4.2008.
45. Sami Neza: Albanija 2008, predviđanja i izazovi. SETimes, 18.2.2008.
46. Daniel Daianu: Uglavnom dobre vijesti za rumunjsko gospodarstvo. SETimes, 30.10.2006.
47. Georgi Mitev-Shantek: *Na obzoru mogućnost balkanskog biogoriva*. SETimes, 21.08.2006.
48. Igor Jovanović: Režim viza predstavlja jedinstveno pitanje za zapadni Balkan. SETimes, 05.06.2006.
49. Davor Konjikušić: U Srbiji u tijeku oporavak nakon poplava. SETimes, 22.05.2006.
50. Antonela Arhin: Napredak reforme obrane Srbije i Crne Gore. SETimes, 13.02.2006.
51. Daniel Daianu: Cijene nafte i nova gospodarstva mijenjaju sliku svijeta. SETimes, 03.01.2006.
52. Dušan Kosanović: Košarka zbližava bivše jugoslavenske republike. SETimes, 14.11.2004.
53. Beth Kampschorr: Države na teritoriju bivše Jugoslavije počinju se baviti ratnim zločinima na lokalnim sudovima. SETimes, 11.10.2004.
54. Zoran Nikolovski: Naznake gospodarskog oporavka pružaju Makedoncima nadu u bolji život. SETimes, 24.10.2005.
55. Daniel Daianu: EU referendumi otežavaju planirani tijek akcesije. SETimes, 04.07.2005.
56. Svetla Dimitrova: Izvješće ističe probleme s jednakošću spolova u istočnoj Europi. SETimes, 16.05.2005.
57. Davor Konjikušić: *Dvije godine Ustavne povelje*. SETimes, 07.03.2005.

#### Popularno-znanstveni tekstovi:

58. Bryan Sykes: Sedam Evinih kćeri: genetička povijest Europljana. Naklada Zadro, Zagreb, 2002. str.3-6. (B) (prijevod: Mirna Petani)
59. Bryan Sykes: Sedam Evinih kćeri: genetička povijest Europljana. Naklada Zadro, Zagreb, 2002. str.124-126. (M) (prijevod: Mirna Petani)

60. Bryan Sykes: Sedam Evinih kćeri: genetička povijest Europljana. Naklada Zadro, Zagreb, 2002. str.253-254. (E) (prijevod: Mirna Petani)
61. Richard Dawkins: Sebični gen. Izvori, Zagreb, 2007. str.11-12. (B) (prijevod: Petar Kružić)
62. Richard Dawkins: Sebični gen. Izvori, Zagreb, 2007. str.190-192. (M) (prijevod: Petar Kružić)
63. Richard Dawkins: Sebični gen. Izvori, Zagreb, 2007. str.294-295. (E) (prijevod: Petar Kružić)
64. Bill Bryson: Kratka povijest gotovo svega. Makronova, Zagreb, 2004. str.9-10. (B) (prijevod: Milica Lukšić, Sanja Petrovečki)
65. Bill Bryson: Kratka povijest gotovo svega. Makronova, Zagreb, 2004. str.213-214. (M) (prijevod: Milica Lukšić, Sanja Petrovečki)
66. Bill Bryson: Kratka povijest gotovo svega. Makronova, Zagreb, 2004. str.420-422. (E) (prijevod: Milica Lukšić, Sanja Petrovečki)
67. Steve Jones: Y: Porijeklo muškarca. Naklada Jesenski i Turk, Zagreb, 2006. str.17-19. (B) (prijevod: Goran Vujasinović)
68. Steve Jones: Y: Porijeklo muškarca. Naklada Jesenski i Turk, Zagreb, 2006. str.131-132. (M) (prijevod: Goran Vujasinović)
69. Steve Jones: Y: Porijeklo muškarca. Naklada Jesenski i Turk, Zagreb, 2006. str.255-258. (B) (prijevod: Goran Vujasinović)
70. Misha Glenny: McMačija: kriminal bez granica. Naklada Ljevak, Zagreb, 2008. str.19-21. (B) (prijevod: Sanja Ščibajlo)
71. Misha Glenny: McMačija: kriminal bez granica. Naklada Ljevak, Zagreb, 2008. str.236-238. (M) (prijevod: Sanja Ščibajlo)
72. Misha Glenny: McMačija: kriminal bez granica. Naklada Ljevak, Zagreb, 2008. str.447-450. (E) (prijevod: Sanja Ščibajlo)
73. Stephen Hawking: Ilustrirana kratka povijest vremena. Izvori, Zagreb, 2004. str.9-11. (B) (prijevod: Damir Mikuličić)
74. Stephen Hawking: Ilustrirana kratka povijest vremena. Izvori, Zagreb, 2004. str.120-121. (M) (prijevod: Damir Mikuličić)
75. Stephen Hawking: Ilustrirana kratka povijest vremena. Izvori, Zagreb, 2004. str.234-237. (E) (prijevod: Damir Mikuličić)

#### JAMA-HR:

76. Fitzgibbons RJ, Giobbie-Hurder A, Gibbs JO, et al. Pozorno praćenje bolesnika u odnosu na operaciju preponske kile u muškarca s minimalnim simptomima. JAMA-HR 2006;3:173-180. (B) (prijevod: mr.sc. Leo Pažanin, dr.med.; original: JAMA 2006;295:285-292)
77. Fitzgibbons RJ, Giobbie-Hurder A, Gibbs JO, et al. Pozorno praćenje bolesnika u odnosu na operaciju preponske kile u muškarca s minimalnim simptomima. JAMA-HR 2006;3:173-180. (M) (prijevod: mr.sc. Leo Pažanin, dr.med.; original: JAMA 2006;295:285-292)
78. Fitzgibbons RJ, Giobbie-Hurder A, Gibbs JO, et al. Pozorno praćenje bolesnika u odnosu na operaciju preponske kile u muškarca s minimalnim simptomima. JAMA-HR 2006;3:173-180. (E) (prijevod: mr.sc. Leo Pažanin, dr.med.; original: JAMA 2006;295:285-292)
79. Walsh JME, Pignone M. Farmakološko liječenje hiperlipidemije u žena. JAMA-HR 2004;4:311-321. (B) (prijevod: doc.dr.sc. Vlatka Brumen, dr.med.; original: JAMA 2004;291:2243-2252)
80. Walsh JME, Pignone M. Farmakološko liječenje hiperlipidemije u žena. JAMA-HR 2004;4:311-321. (M) (prijevod: doc.dr.sc. Vlatka Brumen, dr.med.; original: JAMA 2004;291:2243-2252)
81. Walsh JME, Pignone M. Farmakološko liječenje hiperlipidemije u žena. JAMA-HR 2004;4:311-321. (E) (prijevod: doc.dr.sc. Vlatka Brumen, dr.med.; original: JAMA 2004;291:2243-2252)

82. van Walraven C, Hart RG, Singer DE, et al. Usporedba oralnih antikoagulansa i aspirina u nevalvularnoj fibrilaciji atrijske. JAMA-HR 2003;2:125-133. (B) (prijevod: mr.sc. Ivana Bušljeta, dr.med.; original: JAMA 2002;288:2441-2448)
83. van Walraven C, Hart RG, Singer DE, et al. Usporedba oralnih antikoagulansa i aspirina u nevalvularnoj fibrilaciji atrijske. JAMA-HR 2003;2:125-133. (M) (prijevod: mr.sc. Ivana Bušljeta, dr.med.; original: JAMA 2002;288:2441-2448)
84. van Walraven C, Hart RG, Singer DE, et al. Usporedba oralnih antikoagulansa i aspirina u nevalvularnoj fibrilaciji atrijske. JAMA-HR 2003;2:125-133. (E) (prijevod: mr.sc. Ivana Bušljeta, dr.med.; original: JAMA 2002;288:2441-2448)
85. Piccirillo JF, Mager DE, Frisse MR, et al. Značajnost antibiotika prvog izbora u odnosu na antibiotike drugog izbora za liječenje akutnog nekompliciranog sinuitisa. JAMA-HR 2002;1:33-40. (B) (prijevod: Mirka Berendika, dr.med.; original: JAMA 2001; 286:1849-1856)
86. Piccirillo JF, Mager DE, Frisse MR, et al. Značajnost antibiotika prvog izbora u odnosu na antibiotike drugog izbora za liječenje akutnog nekompliciranog sinuitisa. JAMA-HR 2002;1:33-40. (M) (prijevod: Mirka Berendika, dr.med.; original: JAMA 2001; 286:1849-1856)
87. Piccirillo JF, Mager DE, Frisse MR, et al. Značajnost antibiotika prvog izbora u odnosu na antibiotike drugog izbora za liječenje akutnog nekompliciranog sinuitisa. JAMA-HR 2002;1:33-40. (E) (prijevod: Mirka Berendika, dr.med.; original: JAMA 2001; 286:1849-1856)
88. Lipton, RB, Stewart WF, Stone, AM, et al. Strategija stratificiranog liječenja u odnosu na strategije stupnjevito liječenja migrene. Studija onesposobljenosti u strategijama liječenja: randomizirani pokus. JAMA-HR 2001;2:89-96. (B) (prijevod: mr.sc. Leo Pažanin, dr.med.; original: JAMA 2000; 284:2599-2605)
89. Lipton, RB, Stewart WF, Stone, AM, et al. Strategija stratificiranog liječenja u odnosu na strategije stupnjevito liječenja migrene. Studija onesposobljenosti u strategijama liječenja: randomizirani pokus. JAMA-HR 2001;2:89-96. (M) (prijevod: mr.sc. Leo Pažanin, dr.med.; original: JAMA 2000; 284:2599-2605)
90. Lipton, RB, Stewart WF, Stone, AM, et al. Strategija stratificiranog liječenja u odnosu na strategije stupnjevito liječenja migrene. Studija onesposobljenosti u strategijama liječenja: randomizirani pokus. JAMA-HR 2001;2:89-96. (E) (prijevod: mr.sc. Leo Pažanin, dr.med.; original: JAMA 2000; 284:2599-2605)