

Miroslav Tuđman:

Zakon o veličini vokabulara teksta

*Heapsov zakon i određivanje veličine vokabulara tekstova na
hrvatskom jeziku*

Verzija 4: 06.10.2004.

Uvod

Lotkin zakon o produktivnosti autora, Bradfordov zakon o pravilnosti razdiobe članaka po časopisima, te Zipfov zakon o razdiobi riječi u tekstu, tri su temeljna zakona na kojima se temelje empirijska istraživanja u informacijskoj znanosti. Ovi zakoni doživjeli su svoje modifikacije i različite interpretacije (V. Oluić-Vuković), a postoje i pokušaji da se sva tri zakona izvedu iz jedne jednadžbe ili svedu na jednu zajedničku logiku.

Puno je manje poznat u teoriji, a također i manje primjenjivan u praksi Heapsov zakon.


Heapsov zakon (Heaps, 1978) omogućava izračunavanje fonda riječi, tj. veličine vokabulara, koji se koristi u nekom dokumentu, ili nizu dokumenata. Zakon je formuliran na sljedeći način:

$$(1) \quad V_R(n) = Kn^\beta$$

V_R je oznaka za dio vokabulara ($V_R \subseteq V$) koji se koristi u tekstu veličine **n** . **K** i **β** su parametri koji se određuju empirijski. Za korpus tekstova na engleskom jeziku, vrijednost **K** je između 10 i 100, a za **β** iznosi:

$$0,4 \leq \beta \leq 0,6$$

Tipične razdiobe vokabulara prema Heapsovom zakonu prikazane su na sljedećem grafikonu (www.PlanetMathOrg\PlanetMathHeaps'law.htm)



- Na osi x prikazane su veličine teksta, a osi y veličina vokabulara, tj. fonda riječi koji se koristi u tekstu određene veličine.

Heapsov zakon u teoriji informacijske znanosti nije nepoznat (Gelbukh, 2001, Turner, 2001) ali se o njemu manje raspravlja i manje se koristi nego ostali bibliometrijski zakoni: Bradfordov, Lotkin i Zipfov zakon. Tome su vjerojatno tri razloga.

Prvo, Heapsova formula za izračunavanje veličine vokabulara (tj. fonda riječi) nekog teksta, po svojoj formi odgovara metodi najmanjih kvadrata, i iste rezultate možemo dobiti koristeći standardne statističke programe (poput SPSS).

Drugo, Heapsova formula nije univerzalna jer ne vrijedi za sve jezike (Gelbukh, 2001). Odnos fonda riječi, tj. korištenog vokabulara i veličine teksta različit je od jednog jezika do

drugog. Kao dokaz za ovu tezu dostatan je i primjer knjige Antoine de Saint-Exupery «Mali Princ» na osam jezika:

Tekst	Veličina teksta	Vokabular Vr	Funkcionalne riječi Fs
Mali Princ engleska prijevod	16884	2203	4953
Mali Princ njemački prijevod	14354	2664	3951
Mali Princ Španjolski prijevod	13612	2865	4462
Mali Princ češki prijevod	13500	3141	2370
Mali Princ talijanski prijevod	13213	2558	4934
Mali Princ hrvatski prijevod	13029	3250	2595
Mali Princ poljski prijevod	12810	3364	1850
Mali Princ srpski prijevod	12411	3332	2335

Tabela 1: «Mali Princ» na osam jezika; osam tekstova i vokabulara različitih veličina

Iz ovog je primjera već razvidno da je jedna te ista poruka («Mali Princ») na različitim jezicima iskazana različitom dužinom teksta. (Engleska verzija ima 36% više riječi od srpske verzije). Odnos između veličine vokabulara i veličine teksta kreće se od 1:4 do 1:8. Ukupan broj je funkcionalnih riječi također različit: od 1/3 do 1/7 od ukupnog broja riječi u tekstu.

Treće, činjenica je da bi se prema Heapsovom zakonu vrijednosti parametara i α i β trebale određivati empirijski. Dosadašnja pak istraživanja potvrdila su prvenstveno njihove vrijednosti za engleski jezik. Da bi se Heapsov zakon mogao primjenjivati u istraživanju vokabulara tekstova na jezicima koji nisu engleski, trebalo bi izračunati vrijednosti

parametara κ i β za svaki jezik posebno. Takva istraživanja očito nisu brojna, a primjena Heapsova zakona u istraživanju korpusa tekstova na hrvatskom jeziku na samom su početku (M. Tuđman, 2003.a, 2003.b).

2. Problem

Problem kojim se bavimo u našem istraživanju je primjena Heapsova zakona u istraživanju vokabulara tekstova na hrvatskom jeziku. Zato je potrebno odrediti vrijednosti parametara κ i β koje bi vrijedile za obradu korpusa hrvatskih tekstova. Potrebno je odrediti empirijske vrijednosti parametara κ i β ali i istražiti (međusobnu) uvjetovanost veličina tih parametara. Zato su pitanja na koja tražimo odgovore: u kakvima su odnosima vrijednosti parametara κ i β s drugim odrednicama veličine vokabulara tekstova na hrvatskom jeziku? Želimo istražiti može li Heapsov zakon naći svoju primjenu u izračunavanju veličine vokabulara tekstova na hrvatskom jeziku, ali i za izračunavanje broja funkcionalnih riječi, jednokratnih riječi, te najfrekventnije riječi u pojedinim tekstovima ili korpusu tekstova?

3. O terminologiji

Terminologija koja se koristi u analizi jezičnih korpusa nije ustaljena. Jednako tako termini koji se rabe u primjeni Heapsova zakona nisu standardizirani, ili se pak rabe uvjetno, s određenim ograničenjima. Zato ćemo izložiti kako smo koristili neke osnovne termine vezane za tumačenje Heapsova zakona.

- **Veličina teksta** (text size) određena je ukupnim brojem riječi koje se pojavljuju u tekstu. No i **broj pojavnica** (token) uvriježeni je naziv za ukupan broj riječi teksta, za sve riječi koje tvore neki tekst. Zato se *veličina teksta* i *broj pojavnica teksta*, rabe kao termini koji označavaju isti sadržaj.
- **Veličina vokabulara teksta** određena je fondom riječi koje se rabe u nekom tekstu. Vokabular teksta je rječnik teksta, preciznije vokabular je fond različnica (types) jednog teksta. Veličina vokabulara i broj različnica teksta koriste se kao termini koji označavaju isti sadržaj: broj različitih riječi u tekstu.
 - Različnice u istraživanju korpusa (kako engleskih tako i hrvatskih) tekstova nisu lematizirane (tj. svedene na osnovni oblik – nominativ ili infinitiv). Zato se (semantički) ista riječ može pojaviti više puta kao različnica u vokabularu tekstu, ako se javlja u izmijenjenom obliku (u različitim padežima ili vremenima).
 - Posljedica i ograničenje ovakvog određivanja veličine vokabulara teksta jest u tome da flektivni jezici s razgranatom morfologijom imaju veći vokabular od jezika čija morfologija nije jednako razgranana.
- **Funkcionalne riječi** su sinonim za «gramatičke riječi», «prazne riječi», ili «stop words». Funkcionalne riječi tvore mali i konačni razred riječi kao što su prijedlozi (*u, na, s, od, do, pri*, itd.).

veznici (*i*, *ili*, *ni*, itd.) odnosno članovi u nekim jezicima (*a*, *the*, npr. u engleskom). Funkcionalne riječi tvore ***zatvoreni razred*** riječi (R. Carter, 1998), one su malobrojne i same za sebe ne nose semantičke poruke, već služe za gramatičku tvorbu teksta. Zato su to najfrekventnije riječi u tekstu.

- **Hapax legomena** (grč. u značenju «jednom izgovoren») koristi se kao termin u analizi veličine tekstova, kao oznaka za one riječi koje se javljaju jednokratno, samo jedanput, ili preciznije čija je frekvencija pojavljivanja jedan. Da bismo označili riječi koje se javljaju jednokratno u tekstu, koristili smo kao sinonime termine ***hapax legomena***, ***jednokratne riječi***, odnosno ***jednokratnice***.
- **Višekratne riječi** ili **višekratnice** koristimo kao termin da bismo opisali one riječi u tekstu čija je frekvencija pojavljivanja veća od jedan. Jednokratnice i višekratnice tvore vokabular teksta, s time da se jednokratnice javljaju samo jedanput u cijelom tekstu.
- **Maksimalna frekvencija** je oznaka vrijednosti za onu riječ koja se najviše puta javlja u nekom tekstu.

4. O metodi

Analizu vokabulara tekstova na hrvatskom jeziku radili smo na korpusu koji se sastoji od 111 hrvatskih tekstova, ili ukupno 5.343.624 pojavnica. Tekstovi su preuzeti u digitalnoj formi i nisu posebno prilagođavani za ovu analizu. Pri odabiru tekstova nastojali smo uvrstiti samo prozne tekstove, tako da ne bude velike razlike u žanrovima. (Korpus od 111 tekstova,

nastao je od nova 42 teksta koja su pridodana korpusu od 69 tekstova što smo ih analizirali u radu M. Tuđman, i dr. 2003.)

Kao kontrolnu grupu koristili smo korpus od 35 tekstova na engleskom jeziku, korpus veličine 4.536.115 pojavnica. I ovaj korpus sastoји se pretežno od književnih tekstova, jer pretpostavljamo da na razlike u veličini vokabulara tekstova mogu imati utjecaj i pojedini žanrovi sa svojim stilskim specifičnostima.

Svaki je tekst iz korpusa odabranih tekstova podvrgnut obradi kako bi se dobili osnovni podaci o tekstu: veličina teksta (broj pojavnica), veličina vokabulara (broj različnica), broj funkcionalnih riječi, broj jednokratnih i broj višekratnih riječi, pregled različnica po frekvenciji (izdvojili smo maksimalnu frekvenciju u svakom tekstu). (Obradom smo došli još do niza podataka, koji nisu predmetom ove analize: broj znakova, broj slova, broj paragrafa, broj rečenica teksta.) Softverski program za ovu obradu izradio je prof. dr. Damir Boras u okviru projekta «Modeli znanja i obrada prirodnog jezika».

Nismo radili lematizaciju, tako da se rezultati analize veličine vokabulara tekstova mogu koristiti samo za kvantitativne a ne i za kvalitativne prosudbe.

Statistička analiza podataka rađena je u Excelu, a grafički prikaz u Microsoft Wordu.

Rezultati statističke obrade podataka korpusa tekstova na hrvatskom jeziku i korpusa tekstova na engleskom jeziku prikazani su u prilogu: M. Tuđman, D. Boras, N. Mikelić «Heapsov zakon i određivanje veličine vokabulara tekstova na hrvatskom jeziku. Dokumentacija» (Filozofski fakultet, Zagreb, 2004).

Bez spoznaja do kojih smo došli analizirajući podatke prikazane u spomenutoj «Dokumentaciji», nije moguća analiza Heapsova zakona u ovom radu. Nažalost, zbog obujma dokumentacije prikupljene i obrađene analizom vokabulara tekstova na hrvatskom jeziku, nismo u mogućnosti cijelu građu uvrstiti u ovaj članak već se možemo samo na nju pozivati. Međutim, osnovni podaci ovog empirijskog istraživanja prikazani su u Tabeli 2. Tako se rezultati istraživanja na koja upućuju naredni grafikoni i formule, mogu provjeriti priloženim podacima u tabeli 2.


5. Rezultati (1): konstante u Heapsovom zakonu

5.1 Broj funkcionalnih riječi je konstantan

U Heapsovom zakonu K i β su parametri koji se određuju empirijski. No što utječe na njihovo određivanje i mogu li ovi parametri, ili jedan od njih, imati stalnu vrijednost za pojedine jezike?

Na Grafikonu 1. prikazan je rast vokabulara ($V(n)$), broja funkcionalnih pojavnica (F_s) i maksimalne frekvencije (MF) u ovisnosti o veličini teksta (n). S veličinom teksta rastu i svi ostali pokazatelji, i imaju isti trend rasta, svi osim funkcionalnih riječi. Naime, kod tekstova većih od 60.000 riječi, broj funkcionalnih pojavnica postaje veći od veličine vokabulara. Međutim, pravi pokazatelj o odnosu broja funkcionalnih pojavnica i veličine teksta može se vidjeti na Grafikonu 2.

Grafikon 1: Logaritamski prikaz osnovnih pokazatelja analiziranih tekstova



Analizom podataka o broju funkcionalnih pojavnica u tekstu, možemo zaključiti da je u prosjeku 21% funkcionalnih riječi u svakom tekstu. Štoviše, čak i ukupan broj riječi cijelog korpusa / $N=5.343.624$ podijeljene s ukupnim brojem funkcionalnih riječi $Fr=1.093.554/$ upućuje na isti zaključak jer daje sljedeći rezultat: 20,46% (Tabela 2).

Tabela 2. Osnovni podaci za analizu vokabulara hrvatskih tekstova

	Oznaka teksta	Veličina teksta: broj pojavnica	Vokabular: različni ce	Izračunati vokabular $VRt = (N*k)^{2/3}$	Fs: broj funkcionalnih riječi	% funkcionalnih riječi	Izračun fukcion alnih riječi Ft $= n*0,21$	Hapax legome na HLs: frekven . = 1	HLt = $((N*k)/2)^{2/3}$	MFs: maksim alna frekven cija	MFt = $N^*(0,21)^{2/3}$
1.	Milos Petar pan	681	425	608	135	19,82	143	336	382	25	30
2.	Milos Jezero	706	422	623	123	17,42	148	330	392	23	31
3.	Milos Povratak	723	453	633	122	16,87	152	363	398	22	32
4.	Milos Gibraltar	815	515	686	134	16,44	171	422	431	29	36
5.	Milos Ex picador	886	509	726	178	20,09	186	395	456	36	39
6.	Kovacina Bakrena Svila	922	681	745	142	15,40	194	592	468	43	41
7.	Milos Penelope	949	544	760	209	22,02	199	416	477	29	42
8.	Lokotar Eseji o moru	999	617	786	209	20,92	210	508	494	36	44
9.	Kovacina Paucina	1281	779	929	251	19,59	269	641	584	53	56
10.	Kovacina Ljepota	1318	699	947	235	17,83	277	535	595	71	58
11.	Milos Afrodizijak	1415	851	993	262	18,52	297	681	624	38	62
12.	NekocSad-pogovor	1702	985	1124	321	18,86	357	796	706	86	75
13.	Skolarac-pogovor	1758	1061	1148	382	21,73	369	866	722	100	78
14.	TonioKroger-pogovor	2149	1218	1314	422	19,64	451	978	826	124	95
15.	Ljubej Prica	2271	1157	1363	469	20,65	477	865	857	113	100
16.	Branislavljevic Mosq	2510	1324	1458	472	18,80	527	1044	916	111	111
17.	ZudnjaZaLjubavlju-pogovor	3261	1699	1737	643	19,72	685	1312	1092	179	144
18.	O-tragicnom-pogovor	3336	1740	1764	702	21,04	701	1340	1109	181	147
19.	LjudskaSudbina-pogovor	3403	1893	1787	674	19,81	715	1484	1123	152	150


20.	BerlinAlexanderPlatz-pogовор	3723	2002	1898	684	18,37	782	1556	1193	139	164
21.	BranislavljevicVjeverica	3819	1666	1931	742	19,43	802	1242	1214	246	168
22.	VremenskiStroj-pogовор	3927	1903	1967	837	21,31	825	1460	1237	150	173
23.	Ivanhoe-pogовор	4055	1961	2010	846	20,86	852	1489	1263	161	179
24.	PutDolnije-pogовор	4130	2014	2035	901	21,82	867	1539	1279	195	182
25.	Goli-i-mrtvi-pogовор	4201	2162	2058	885	21,07	882	1713	1294	235	185
26.	1984-pogовор	4361	2131	2111	919	21,07	916	1608	1327	171	192
27.	Kontrapunkt-pogовор	4789	2315	2247	970	20,25	1006	1746	1412	198	211
28.	Kis-Zenik	4862	1795	2270	1250	25,71	1021	1260	1427	212	214
29.	PlodoviGnjeva-pogовор	4898	2466	2281	1019	20,80	1029	1907	1434	264	216
30.	Mazuranic1	6134	2492	2653	941	15,34	1288	1692	1667	140	271
31.	BlagaJeNoc-pogовор	7828	3581	3123	1634	20,87	1644	2730	1963	402	345
32.	Tomic OpancarevaKci	8994	3091	3428	1808	20,10	1889	2125	2154	273	397
33.	Pasagic	10927	3571	3906	2148	19,66	2295	2375	2455	300	482
34.	Donadini Bauk	11772	3556	4105	2380	20,22	2472	2478	2580	466	519
35.	princ hr	13029	3250	4394	2595	19,92	2736	2011	2657	420	542
36.	Aralica1	12480	4132	4269	2989	23,95	2621	2898	2683	597	550
37.	Senoa1	13001	4347	4388	1752	13,48	2730	2712	2758	264	573
38.	Senoa Karanfil	13775	5183	4561	2455	17,82	2893	3696	2867	445	607
39.	Kis-Objijalo	14650	4968	4753	3203	21,86	3077	3572	2988	705	646
40.	Aralica4	14813	4531	4789	3533	23,85	3111	3099	3010	712	653
41.	Aralica3	15808	5074	5002	3672	23,23	3320	3448	3144	772	697
42.	Senoa Prijan Lovro	18148	6227	5487	3064	16,88	3811	4202	3448	484	800
43.	Aralica5	18647	5654	5587	4344	23,30	3916	3930	3512	873	822
44.	Aralica2	18930	6123	5644	4201	22,19	3975	4318	3547	836	835

45.	Donadini-Novele	19609	5630	5779	3782	19,29	4118	3930	3632	826	865
46.	TonioKroger	20058	6321	5867	4421	22,04	4212	4386	3687	1074	885
47.	Aralica9	21360	6205	6120	4982	23,32	4486	4184	3846	921	942
48.	Novak1	22807	6607	6394	4487	19,67	4789	4442	4019	1050	1006
49.	Aralica6	23494	6823	6523	5484	23,34	4934	4645	4100	1182	1036
50.	Lisac-Savrsemi krug	24512	6838	6711	4870	19,87	5148	4645	4218	981	1081
51.	Aralica7	24917	6881	6785	5866	23,54	5233	4602	4264	1176	1099
52.	Hlapic	24930	4402	6787	5302	21,27	5235	2367	4266	1388	1099
53.	Jorgovanić	25702	7905	6927	5261	20,47	5397	5448	4354	1038	1133
54.	Donadini-Kroz sibe	28727	7142	7463	5715	19,89	6033	4788	4691	1881	1267
55.	Irena vrklijan	30019	8011	7687	6160	20,52	6304	5182	4831	1311	1324
56.	Skolarac	32259	8568	8066	7211	22,35	6774	5530	5070	1512	1423
57.	Senoa Cuvaj se	32269	9010	8068	5680	17,60	6776	5584	5071	814	1423
58.	Wiesner- Livadic Novele	32923	8437	8177	6593	20,03	6914	5586	5140	1450	1452
59.	Kozarac Djuka	33453	9620	8265	7648	22,86	7025	6768	5195	2109	1475
60.	Kamov Novele	34526	9056	8442	7396	21,42	7250	6075	5306	2065	1523
61.	Leskovar Propali dvori	36674	9384	8790	7100	19,36	7702	6173	5525	1444	1617
62.	Gjalski-Dolazak Hrvata	38234	10006	9039	8355	21,85	8029	6338	5681	2352	1686
63.	Leskovar Novele	39616	9780	9257	8312	20,98	8319	6489	5818	1300	1747
64.	Kovacic I.G. Pripovijetke	39814	13821	9288	7906	19,86	8361	9693	5837	1764	1756
65.	Kovacic Pripovijesti	42054	11969	9635	7534	17,92	8831	8039	6055	1302	1855
66.	MinistarObrane	42271	9219	9668	9211	21,79	8877	5873	6076	2677	1864
67.	Kozarac1	42575	9831	9715	8741	20,53	8941	6493	6106	1629	1878
68.	Aralica8	43572	8379	9866	9846	22,60	9150	3015	6201	2036	1922
69.	Price iz Davnine	44027	9225	9935	10367	23,55	9246	5360	6244	1900	1942
70.	Kozarac2	50361	11277	10872	10151	20,16	10576	7541	6833	2008	2221
71.	Gjalski-Borislavic Janko	50521	11876	10895	10700	21,18	10609	7693	6847	1957	2228

72.	Brlic-Jasa Dalmatin	50961	14535	10958	10093	19,81	10702	9360	6887	2071	2247
73.	Tomic2	52217	11560	11138	10587	20,28	10966	6940	7001	2122	2303
74.	Nasivasi	52966	9737	11245	9889	18,67	11123	5794	7068	2498	2336
75.	Skola-Plivanja	54021	12007	11395	12051	22,31	11344	7563	7162	1858	2382
76.	Matos_Pripovijetke	54933	17652	11523	12042	21,92	11536	12278	7242	2395	2423
77.	Kovacic Fiskal	55761	13526	11639	10494	18,82	11710	8667	7315	1846	2459
78.	Senoa Prosjak Luka	55985	10432	11671	10343	18,47	11757	6055	7335	1882	2469
79.	TajnaJednogVideo zapisa	58938	12193	12080	11844	20,10	12377	7186	7592	2300	2599
80.	Kumicic2	59687	10250	12182	10697	17,92	12534	5819	7657	2178	2632
81.	Usmene narodne price	60253	10517	12259	13502	22,41	12653	4499	7705	2336	2657
82.	NekocSad	62149	12462	12517	13487	21,70	13051	7615	7867	2653	2741
83.	ZudnjaZaLjubavlju	63115	14398	12647	12521	19,84	13254	9433	7949	3358	2783
84.	Kumicic Zacuden svatovi	67831	12742	13272	12990	19,15	14245	7420	8342	2377	2991
85.	Novak2	69282	14660	13462	13779	19,89	14549	9198	8461	2382	3055
86.	LjudskaSudbina	79428	16156	14753	14916	18,78	16680	9798	9272	3374	3503
87.	Senoa3	81500	15493	15009	15597	19,14	17115	8893	9433	2567	3594
88.	O-tragичном OsjecanjuZivota	84097	15202	15328	19802	23,55	17660	9280	9634	3689	3709
89.	Kumicic1	85276	12960	15472	14930	17,51	17908	7166	9724	3169	3761
90.	VremenskiStroj-RatSvjetova	87971	17751	15798	19108	21,72	18474	11103	9929	3824	3880
91.	1984	92242	17819	16308	18781	20,36	19371	10860	10249	4917	4068
92.	Senoa2	95526	17548	16694	16605	17,38	20060	9900	10492	2661	4213
93.	Tomic1	97411	17534	16914	18129	18,61	20456	10509	10631	4958	4296
94.	PutDolndije	99062	18331	17106	20340	20,53	20803	11232	10751	4445	4369
95.	Gjalski1	100702	21243	17295	20206	20,07	21147	13274	10870	3816	4441
96.	BlagajeNoc	101775	21454	17418	19525	19,18	21373	13861	10948	6183	4488
97.	Simunovic Pripovijetke	103691	19039	17637	25483	24,58	21775	7767	11085	5842	4573

98.	DrugoLiceMarketin ga	107788	21689	18101	25420	23,58	22635	13457	11377	4598	4753
99.	Kamov Isusena kaljuza	108598	21452	18192	23673	21,80	22806	13127	11434	6823	4789
100.	Jagma	114720	20438	18873	23177	20,20	24091	12013	11862	4548	5059
101.	Gjalski2	126203	22229	20119	25653	20,33	26503	13312	12645	4093	5566
102.	BerlinAlexanderPlatz	137531	19835	21312	30635	22,27	28882	11538	13394	5162	6065
103.	Kovacic1	144724	26603	22052	29612	20,46	30392	16209	13860	7156	6382
104.	Ivanhoe	149596	26951	22547	28824	19,27	31415	15439	14171	4709	6597
105.	Kontrapunkt	154148	29265	23004	30035	19,48	32371	17950	14458	6838	6798
106.	PlodoviGnjeva	164244	21502	24003	32613	19,86	34491	11845	15086	6526	7243
107.	Kumicic Urota	170792	25622	24640	32796	19,20	35866	14228	15486	5462	7532
108.	Kumicic3	175021	25630	25047	32805	18,74	36754	14228	15742	5463	7718
109.	Aralica1-9	217515	30432	28974	50401	23,17	45678	14284	18210	10287	9592
110.	Goli-i-mrtvi	221609	27788	29338	43193	19,49	46538	14802	18439	9761	9773
111.	Begovic-Giga Bariceva	251013	36021	31892	52678	20,99	52713	21500	20044	10966	11070

Grafikon 2: Postotak funkcionalnih riječi i razlike između Fs i Ft




Isti stalni omjer veličine teksta i broja funkcionalnih riječi u tekstu pokazuju podaci iz kontrolne grupe – za tekstove na engleskom jeziku (Grafikon 3.). Samo u korpusu tekstova na engleskom udio je funkcionalnih pojavnica u veličini teksta 26%.

Grafikon 3. koristi dvije ordinate s različitim skalamama vrijednosti za prikaz veličine teksta, odnosno broj funkcionalnih riječi. To omogućava da se zorno pokaže kako su obje krivulje jednake, odnosno da se omjer između ovih veličina ne mijenja s veličinom teksta.

Zato možemo zaključiti da je postotak funkcionalnih riječi u tekstu konstantan. On za tekstove na hrvatskom jeziku iznosi 21%, a za engleske 26%. Možda bi mogle postojati varijacije između žanrova, no to bi bilo predmetom novih analiza.

Grafikon 3: Veličina teksta i broj funkcionalnih riječi Fs i Ft



Broj stvarnih funkcionalnih riječi (Fs) dobili smo empirijski. Teorijski izračun postotka funkcionalnih riječi (Ft), kada je $K = 21$, pokazuje minimalna odstupanja.

$$(2) \quad \mathbf{Ft} = n \cdot (K/100)$$

Grafički prikaz razlika između Fs i Ft potvrđuje tezu da pokazatelj postotka funkcionalnih riječi u tekstu možemo uzeti kao konstantu za pojedini jezik. Funkcionalne riječi su prazne riječi, služe za gramatičku gradnju rečenica, a ne za oblikovanje obavijesti. Udio broja funkcionalnih pojavnica u tekstu ne mijenja se s veličinom teksta, već ostaje isti. «Problem» jest kod kratkih tekstova do 1000 riječi, gdje je postotak funkcionalnih pojavnica nešto manji (17-20%), i gdje je najveći odmak između stvarnog (Fs) i procijenjenog broja (Ft) svih funkcionalnih riječi (Tabela 2). To je isti problem s kojim su suočeni teoretičari bibliometrijskih zakona, jer je na


početku logaritamske krivulje koja pokazuje bibliometrijske razdiobe najviše odstupanja (V. Olujić-Vuković, 1999, R. Rousseau, 1990).

Analiza obrađenog korpusa tekstova na hrvatskom i engleskom jeziku vode k zaključku da je udio funkcionalnih pojavnica u tim korpusima konstantan i da za hrvatske tekstove $K = 21$, a za engleske $K = 26$.

5.2 Maksimalne frekvencije su konstanta

Ako usporedimo odnose između ukupnog broja funkcionalnih riječi (F_s) i najfrekventnije riječi u tekstu (MFs), možemo zaključiti da se radi o razdiobama koje su pravilne (Tabela 2). To nam pokazuje i grafikon 4.:

Grafikon 4: Odnos broja funkcionalnih riječi i maksimalnih frekvencija




Štoviše, statistička analiza odnosa vodi nas k hipotezi da je odnos veličine teksta prema broju funkcionalnih pojavnica jednak omjeru broja funkcionalnih pojavnica prema maksimalnoj frekvenciji (MF). Zato taj odnos možemo prikazati i na sljedeći način:

$$(3) \quad MF = Ft \cdot (K/100)$$

Odnosno:

$$(4) \quad MF = n \cdot (K/100)^2$$

Grafikon 5: Odnos stvarnih i izračunatih najfrekventnijih riječi (MFs i MFt)




Na Grafikonu 5. prikazani su odnosi između stvarnih (MFs) i izračunatih vrijednosti (MFt), prema formuli (4) za najfrekventnije riječi u analiziranim tekstovima. Odstupanja između stvarnih i izračunatih vrijednosti su puno manja nego u slučajevima nekih drugih bibliometrijskih pojava i procesa; u skoro 40% slučajeva odstupanja su čak manja od $\pm 10\%$ (Tabela

2). Korelacija između stvarnih i izračunatih vrijednosti najfrekventnijih riječi je 0,976.

Na grafikonu 6. prikazane su maksimalne frekvencije za tekstove na engleskom jeziku, stvarne i izračunate:

Grafikon 6: Maksimalne frekvencije riječi u tekstovima - MFs i MFt



I na temelju ovoga grafikona može se zaključiti da su razlike između stvarnih i izračunatih maksimalnih frekvencija u statistički dopuštenim granicama.

5.2 Konstante u Heapsovom zakonu (komentar)

Do sada smo uočili dvije konstatne u analizi teksta:

- Prvo, udio funkcionalnih pojavnica u tekstu, neovisno o duljini teksta, je konstantan;
 - Komentar: funkcionalne riječi ne grade poruku teksta, nego strukturiraju tekst; **K** se može mijenjati prema jezicima i žanrovima ali je konstantan za pojedini jezik i pojedini žanr.
- Drugo, maksimalna frekvencija (MF) u tekstu je konstanta; jer je određuju gradbeni elementi teksta, a ne poruke.
 - MFT izračunata je po formuli:

$$• \text{MFT} = F : (K/100)$$

ili

$$• \text{MFT} = n : (K/100)^2$$

- Komentar: maksimalna frekvencija (MF) uvijek je konstanta i iznosi 4,41% od ukupnog broja pojavnica; odnosno MFT je 4,41% od veličine teksta na hrvatskom jeziku, ili 6,76% od veličine teksta na engleskom jeziku; (prema **K²/100**).
- Treće, možemo zaključiti da postoji i pravilnost u gradnji teksta, odnosno odnosima koji postoje između veličine teksta (n), broja svih funkcionalnih pojavnica (F) i najfrekventnije riječi (MF). Ako je naša analiza točna, onda su ti odnosi sljedeći:
 - $n : F = F : MF$
 - Odnosno: **broj pojavnica ili dužina teksta (n) naprava broju funkcionalnih pojavnica (F) u istom**

je omjeru kao broj funkcionalnih pojavnica prema maksimalnoj frekvenciji (MF).

- Ako je tome tako onda vrijede i sljedeći izvodi:

- $n = F^2/MF$
- $MF = F^2/n$
- $F = (n \cdot MF)^{1/2}$

- Četvrto, nema razloga da se za parametar K u Heapsovu zakonu ne uzme pokazatelj o broju svih funkcionalnih riječi u tekstu. To je empirijska veličina koja se izračunava za broj pojavljivanja svih funkcionalnih riječi u tekstovima na različitim jezicima. Vrijednost ovog parametra u granicama je onoga što je određeno Heapsovim zakonom (1), ali je prednost u tome što se mogu izračunati i drugi pokazatelji relevantni za veličinu teksta.

6. Rezultati (2): varijable u Heapsovu zakonu

6.1 Vrijednost parametra β je konstantna?

Podsjetimo da je Heapsov zakon formuliran na sljedeći način:

$$(1) \quad V_R(n) = Kn^\beta$$

a da su K i β parametri koji se prema Heapsu određuju empirijski. Za korpus tekstova na engleskom jeziku, vrijednost za β iznosi (*Heaps' Law. PlanetMath.Org.*):

$$0,4 \leq \beta \leq 0,6$$

Mogu li se ove vrijednosti teorijski utemeljiti ili samo izvući iz empirije? Vrijednost parametra β za izračunavanje vokabulara tekstova na hrvatskom jeziku iznosi 0,67, ako je K=21 (vidi Tabela 2.; «Dokumentacija»), a prema drugim istraživanjima može iznositi i 0,74 (vidi M. Tuđman, i dr. 2003). No nas interesira je li moguće odrediti po nekoj drugoj osnovi vrijednost parametra β , kako bi bio općevrijedeci, i kako se ne bi morao empirijski određivati u svakom istraživanju posebno.

Podsjetili smo da analitičari vokabulara tekstova na engleskom jeziku tvrde da eksponent β ima vrijednost između 2/5 i 3/5. Naše istraživanje (tabela 2) pokazuje da je vrijednost β za hrvatske tekstove 0,67 ili 2/3. Nije teško zaključiti da su ove vrijednosti zapravo logaritamske vrijednosti od **K/100**.

Naime:

Logaritam broja 0,21 = - 0,67778

Logaritam broja 0,22 = - 0,65757

Logaritam broja 0,23 = - 0,63827

Logaritam broja 0,24 = - 0,61978

Logaritam broja 0,25 = - 0,60205

Logaritam broja 0,26 = - 0,58502

Znamo da je logaritam broj kojim treba potencirati bazu **a** da se dobije broj **x**, tj. iz $a^y = x$, slijedi **y = log a^x** (**y** je logaritam od **x** po bazi **a**).

Ali što je priroda logaritma, i koji je odnos između logaritamskih i aritmetičkih progresija? Već opći rječnici tumače logaritam (*Logos* – govor, odnos, račun, računanje +

arithmos – broj) kao matematički broj uzet u jednoj aritmetičkoj progresiji, koji odgovara broju uzetom u geometrijskoj progresiji, pri čemu su obje progresije prilagođene određenim uvjetima (B. Klaić)

Teorijsko je pitanje možemo li istu paralelu povući i u našem slučaju i zagovarati tezu da je eksponent β u formuli (1) vrijednost logaritma od $K/100$? Zašto bismo mogli zastupati ovakvu hipotezu? Zato što je vrijednost K u formulama (2) i (3) empirijska veličina, parametar pomoću kojeg utvrđujemo omjer veličine teksta i broja funkcionalnih pojavnica (2), odnosno veličine teksta i najfrekventnije pojavnice (3). Ali ako pomoću tog istog parametra K želimo izračunati veličinu vokabulara teksta, onda to znači da odnos funkcionalnih riječi i veličinu vokabulara teksta stavljamo u jednu novu progresiju, koju određuje eksponent β . Zato se i vrijednost K mijenja u malo k , tj. $k = K^\beta$.

To ima za posljedicu da formulu (1) $V_R(n) = K \cdot n^\beta$, trebamo prikazati na sljedeći način:

$$(5) \quad V_R(n) = K^\beta \cdot n^\beta,$$

$$\text{ili} \quad V_R(n) = (k \cdot n)^\beta.$$

Parametari K i k imaju istu početnu vrijednost koja se mijenja kada se koristi za izračunavanje odnosa u različitim progresijama.

Empirijskih potvrda za ovaku vrstu tumačenja možemo naći već u činjenici da pojedini elementi teksta rastu u različitim omjerima: veličina teksta raste eksponencijano u odnosu na vokabular teksta koji raste linearno; ali vokabular teksta raste linearno u odnosu na broj funkcionalnih pojavnica koji

raste eksponencijalno; ili broj jednokratnih riječi raste linearno u odnosu na broj najfrekventnijih riječi koji raste eksponencijalno, itd. (vidi Tabela 2., «Dokumentacija»). Očito je da pojedini elementi teksta rastu različitim progresijama, i da imaju različite protežnosti u tekstu i korpusu tekstova. Neki autori s pravom upozoravaju da «priroda ovih zakona (Zipfova i Heapsova, op. M.T.) nije poznata» (A. Gelbukh, 2001). To nas upućuje na spoznajno-teorijski problem multidimenzionalnosti teksta, i potrebu epistemološkog tumačenja pojedinih dimenzija teksta. Samo bismo na taj način mogli teorijski obrazložiti tezu zašto vrijednost parametra β može biti $\beta = \log K/100$.

Kako se u ovom radu bavimo empirijskom provjerom zakona o veličini vokabulara teksta, tako ćemo samo upozoriti na mogućnost koju treba potvrditi novim istraživanjima, ali i epistemološkim tumačenjima, da vrijednost parametra β može biti logaritam od $K/100$. Što bi značilo i da vrijednost parametra β može biti konstantna za tekstove na istom jeziku.

6.2 Izračun veličine vokabulara tekstova na hrvatskom jeziku

Utvrdili smo da je broj funkcionalnih pojavnica u tekstu konstanan. Postotak funkcionalnih riječi uzeli smo kao vrijednost parametra K . Empirijska istraživanja ukazuju da parametar β može biti logaritamska vrijednost od $K/100$. Zato za formulu (1) za izračunavnjje veličine vokabulara tekstova na hrvatskom jeziku vrijede parametri $K = 21$, i $\beta = \log K/100$, pod uvjetom da izvornu formulaciju Heapsova zakona (1) redefiniramo:

$$(5) \quad V_R(n) = (K \cdot n)^\beta$$

Za ovaku formulaciju zakona o veličini vokabulara teksta nalazimo potvrdu u empirijskim istraživanjima. Teorijsko tumačenje trebalo bi slijediti iz razumijevanja multidimenzionalnosti teksta. Operativno smo u formulu (5) uvrstili parametre do kojih smo došli empirijskim putem:


$$(6) \quad V_R(n) = (21 \cdot n)^{2/3}$$

Odnosno:


$$(6b) \quad V_R(n) = (21 \cdot n)^{0,67}$$

Koristeći ovu formulu dobili smo sljedeće rezultate (Vrt), koji su prikazani na grafikonima 7. i 8. i u Tabeli 2.

Grafikon 7: Prikaz stvarnih i izračunatih vrijednosti vokabulara



Grafikon 8: Udio vokabulara u veličini teksta (u %)



Na oba prethodna grafikona, kao i u Tabeli 2. prikazane su stvarne i izračunate vrijednosti vokabulara tekstova na hrvatskom jeziku. Iz grafikona i tabele 2. možemo zaključiti da je formula (6,6b) pouzdano sredstvo za procjenu vokabulara tekstova, jer je korelacija između dviju varijabli (stvarne i izračunate veličine vokabulara) 0,984.

Pogreška prognoze veličine vokabulara najveća je na početku krivulje, tj. kod tekstova duljine do 1.000 riječi. Kod tekstova veličine do 1.000 riječi udio vokabulara u veličini teksta je oko 60%, a procjene se kreću od 90% do 78%. Kod tekstova veličine od 100.000 do 250.000 riječi stvarni udio vokabulara u odnosu na veličinu teksta pada od 21% prema 14% (odnosno, izračunata vrijednost vokabulara u odnosu na veličinu teksta pada od 17% prema 13%).


Zato moramo postaviti metodološko pitanje: koja je najmanja veličina teksta kojeg možemo smatrati tekstom, odnosno predmetom kvantitativnih analiza? Ili, tekst koje veličine ima značajke koje se mogu kvantitativno analizirati? Prije ili kasnije morat ćemo naći odgovor na ovo pitanje, jer o njemu ovisi i odgovor na pitanje o prihvatljivosti ove ili one formule za izračunavanje veličine vokabulara teksta ili korpusa tekstova.

6.3 Broj jednokratnih riječi u vokabularu teksta je konstantan

Na Grafikonu 9. prikazan je eksponencijani rast i veličine vokabulara teksta, ali i jednokratnih riječi (hapax legomena) u tekstu. Očito je da ove dvije varijable veličine teksta rastu eksponencijalno i da su stalno u istom omjeru. Veličinu vokabulara teksta izračunavamo po formuli (5). Omjer veličine vokabulara i jednokratnih riječi možemo izračunati ako taj

omjer uključimo u formulu (5), jer je očito da se radi o opisu empirijskih odnosa.

Grafikon 9: Prikaz eksponencijalnog rasta vokabulara i hapax legomena



Zato se broj jednokratnih riječi (HL) u tekstu može izračunati prema sljedećoj formuli:

$$(7) \quad HL = ((K \cdot n) / 2)^{\beta}$$


$$(8) \quad HL = ((21 \cdot n) / 2)^{2/3}$$

Odnosno:

$$(9) \quad HL = ((21 \cdot n) / 2)^{0,67}$$

Grafički prikaz odnosa veličine vokabulara, stvarnih (HLs) i izračunatih (HLt) jednokratnih riječi (formula (9)), dat je na grafikonu 10. i u Tabeli 2.


Grafikon 10: Prikaz veličine vokabulara i veličine hapax legomena



Korelacija između stvarne i izračunate vrijednosti jednokratnih riječi je vrlo visoka: 0,956. Statističke razlike između stvarnih i izračunatih vrijednosti i u ovom slučaju su prihvatljive. Osim toga, omjeri koji postoji između broja jednokratnica i teksta te broja jednokratnica i vokabulara teksta pokazuju pravilnosti, koje se mogu očitati i na grafikonu 11.


Već smo upozorili da postoje samo značajnija odstupanja u izračunu vokabulara, ali i jednokratnih riječi (HL), kod kratkih tekstova (do 1000 riječi). Ta se odstupanja možda mogu tumačiti i kao nepreciznosti budući da je parametar **K** izračunat kao prosjek na temelju velikog uzorka. Realni **K** pak varira, jer kod malih tekstova (do 1000 riječi) iznosi čak 17%. Ako se izračunava Vr (vokabular) i HL s realnim **K**, onda su odstupanja u granicama dopuštenog.

Grafikon 11: Postotak jednokratnih riječi u tekstu i vokabularu teksta



Broj višekratnih riječi u tekstu lako se može izračunati kada se zna veličina vokabulara i broj jednokratnih riječi. Kako višekratnice nisu predmet naše analize, već zakon o veličini vokabulara teksta, na grafikonu 12. prikazujemo samo omjere između jednokratnih i višekratnih riječi u analiziranom korpusu tekstova.

Grafikon 12: Broj jedno- i višekratnih riječi u vokabularu teksta



7. Određivanje veličine vokabulara tekstova na hrvatskom jeziku

Izračunanje veličine vokabulara teksta bit će to preciznije što se parametri koji određuju veličinu teksta mogu preciznije odrediti. U našem smo pristupu pošli od empirijskog podatka da je broj svih funkcionalnih pojavnica onaj parametar koji se dosta precizno može odrediti za svaki korpus tekstova na nekom jeziku. Analizirajući podatke o korpusu tekstova koje smo istraživali, ustanovili smo da je κ za korpus tekstova na hrvatskom 21, a za korpus tekstova na engleskom jeziku $\kappa = 26$. Štoviše, ustanovili smo i omjere koji postoje između broja funkcionalnih pojavnica i najfrekventnije riječi. Time smo

dobili empirijsko polazište za istraživanje odnosa između dva parametra u Heapsovom zakonu. Utvrdili smo da drugi parametar (β) može biti logaritam od $K/100$. Slijedom toga naše je istraživanje potvrdilo sljedeće odnose u korpusima tekstova koje smo istraživali, a koji se mogu opisati formulama:

- za broj funkcionalnih pojavnica (F) u tekstu ili korpusu tekstova

$$(2) \quad F = n \cdot (K/100)$$

- za maksimalnu frekvenciju (MF) riječi u tekstu

$$(4) \quad MF = n \cdot (K/100)^2$$

- za veličinu vokabulara (Vr) teksta

$$(5) \quad V_R(n) = (K \cdot n)^\beta$$

- za broj jednokratnih riječi (HL) u (vokabularu) tekstu

$$(7) \quad HL = ((K \cdot n)/2)^\beta$$

Vrijednost je parametara K i β za korpus tekstova (n) na hrvatskom jeziku 21, odnosno 0,67.

Prema ovim formulama izračunate vrijednosti veličine vokabulara teksta, broja funkcionalnih i najfrekventnijih pojavnica, te jednokratnih riječi u tekstu, prikazane su na tabeli 3. Za usporedbu, izračunata je veličina vokabulara (Vr) i prema izvornoj Heapsovoj formuli (1).


Tabela 3: Prikaz teorijskih veličina vokabulara teksta, broja funkcionalnih i najfrekventnijih pojavnica, te jednokratnih riječi u tekstu					
Veličina teksta n	Vokabular $V_r = (n \cdot k)^{0,67}$	Funkcionalne $F = n \cdot k / 100$	$MF = N \cdot (K/100)^2$	Jednokratnice $HL = ((n \cdot k) / 2)^{0,67}$	Heapsova formula $V_r = 21 \cdot n^{0,67}$

5000	2313	1050	221	1454	6317
10000	3680	2100	441	2313	10051
20000	5856	4200	882	3680	15992
30000	7683	6300	1323	4829	20984
40000	9317	8400	1764	5856	25445
50000	10819	10500	2205	6800	29548
60000	12225	12600	2646	7683	33387
70000	13555	14700	3087	8519	37020
80000	14824	16800	3528	9317	40485
90000	16041	18900	3969	10082	43809
100000	17214	21000	4410	10819	47013
120000	19451	25200	5292	12225	53122
140000	21567	29400	6174	13555	58901
160000	23586	33600	7056	14824	64414
180000	25522	37800	7938	16041	69703
200000	27389	42000	8820	17214	74801
220000	29195	46200	9702	18349	79734
240000	30948	50400	10584	19451	84520
260000	32653	54600	11466	20522	89177

Usporedba podataka sa stvarnim vrijednostima iz tabele 2, sa izračunatim podacima iz tabele 3., upućuje na zaključak o prihvatljivosti predloženih formula. No isto tako možemo razabrati da je izvorna Heapsova formula neuporabljiva, ako želimo kao vrijednost parametra **K** koristiti postotak funkcionalnih riječi u tekstu.


Iako se to može razabrati iz podataka tabele 3, na sljedećem je grafikonu (13) još očitije da tekstovi i korpusi teksova rastu eksponencijalno, a da veličine vokabulara tekstova rastu po drugoj progresiji.

Grafikon 13: Teorijske veličine teksta i vokabulara



Grafički prikaz veličina vokabulara tekstova i svih funkcionalnih riječi prikazan je na grafikonu 14. I ovdje ukupan broj funkcionalnih pojavnica raste eksponencijalno, a veličina vokabulara linearno. No, daleko je važnije podsjetiti da je postotak funkcionalnih pojavnica u tekstovima stalan, i zato tu vrijednost možemo koristiti kao parametar u formuli za izračuvnavanje veličine vokabulara teksta.

Grafikon 14: Teorijske veličine vokabulara teksta i funkcionalnih riječi u tekstu



Predložene formule za izračunavanje veličine vokabulara tekstova, broja svih funkcionalnih pojavnica u tekstovima, broja jednokratnih riječi i najfrekventnije riječi, imaju empirijsku potvrdu u našim istraživanjima. Naša formula temelji se pak na Heapsovou zakonu, i izvedena je iz njega. Kako je ipak Heapsova formulacija zakona o veličini vokabulara teksta ponešto izmijenjena, to je potrebno da naredna istraživanja potvrde uporabljivost, predloženih formuli, te vrijednost parametara za tekstove na hrvatskom jeziku.

8. Moguće primjene zakona o veličini vokabulara teksta

Heapsov se zakon nije ustalio kao istraživačka metoda, iz razloga koje smo naveli u uvodnom dijelu. Zato je još uvjek sam zakon predmetom istraživanja (G.R. Turner, 2001, A. C.

Fang, 2003) i pokušaja da se definiraju parametri presudni za njegovo razumijevanje (C.M. Urzua, 2000, A. Gelbukh, 2001).

Heapsov zakon smatra se izvedenicom iz Zipfova zakona i zato je povezan s istraživanjem jezika. Međutim sve više ima svoju primjenu u istraživanju kvantitativnih odrednica tekstova, korpusa tekstova te umreženih tekstova na internetu.

Na to upućuju pokušaji primjene toga zakona u različitim područjima. Naznačimo samo neka istraživanja koja se rade u nabrojanim područjima, iako čini se da istraživači međusobno nisu upućeni jedni na druge. Ova istraživanja navodimo kao primjere moguće primjene Heapsova zakona, a ne kao temeljna istraživanja za ta područja.

U lingvistici Heapsov zakon ima svoju primjenu u istraživanju veličine vokabulara teksta (G.R. Turner 2001, P. Batke), leksičke gustoće i segmenata diskursa (J. Ure, 1971, L.Y.L. Cheung, 2001, P. Batke), te topologije teksta (M.M.A. Juillard). Svoju primjenu izgleda da će naći i u istraživanju podataka na web stranicama (J. C. French), te istraživanju veličine servera i broja HTML dokumenata (S. Sanguanpong).

Nije teško pretpostaviti i druga područja primjene ovoga zakona: u kriptologiji i zaštiti podataka. Ali i u rekonstrukciji dokumenata i korpusa dokumenata u različitim područjima: od arheologije i povijesti do kvantitativnih metoda za analizu stila i vokabulara djela u književnosti i lingvistici. Analiza vokabulara pojedinih struka ili socijalnih grupa mogu biti od interesa za sociologiju, leksikologiju i kulturnu politiku. Ali isto tako raščlamba i prepoznavanje osnovnog vokabulara jezika socijalnih grupa može biti od koristi za sve one discipline koje komuniciraju putem teksta sa svim tim grupama - bilo u medijima ili u formalnim i

neformalnim komunikacijama. Poznavanje razvoja i rasta vokabulara teksta, te segmenata od kojih se tekst ili korpus tekstova sastoji, može biti od praktične koristi također i za razvoj novih metoda i tehnika učenja (stranih) jezika.

Ovaj zakon zacijelo će imati mnogo primjena, ali prethodno je potrebno razumjeti njegovu prirodu i precizno odrediti parametre bez kojih nije moguće izračunati veličinu vokabulara teksta ili korpusa tekstova.

8. Literatura:

1. Batke P. The Philology and Philosophy Project. Methodology. http://www.princeton.edu/~batke/phph/meth/meth_wml.htm
2. Carter R. Vocabulary. Applied Linguistic Perspectives. London: Routledge; 1998.
3. Cheung L.Y.L., Lai T.B.Y., Tsou B.K., Chik F.C.Y., Luk R.W.P., Kwong O. Y. A preliminary Study of Lexical Density for the Development of XML-based Discourse Structure Tagger., 1st NLP and XML Workshop Tokyo, Nov, 2001.
4. Fang, A. C. STRATA 4.0. Department of Phonetics and Linguistics, University College London. www.phon.ucl.ac.uk/home/alex/project/strata/strata.htm.
5. French. J. C. Modeling Web Data. Department of Computer Science University of Virginia Charlotttesville, VA. french@cs.virginia.edu
6. Gelbukh A., Sidorov G. Zipf and Heaps' Laws Coefficients Depends on Language. <http://www.cic.ipn.mx/~gelbukh/CV/Publications/2001/CICLing-2001-Zipf.htm> [03/19/2003]

7. Heaps H. S. *Information Retrieval: Computational and Theoretical Aspects*. New York: Academic Press; 1978.
8. *Heaps' Law*. PlanetMath.Org.
www.PlanetMathOrg\PlanetMathHeaps'law.htm
9. Juillard, M.M.A., Luong, N.X. New maps of text: a new way to account for the distribution of lexems in texts. Universite Nice-Sophia Antipolis, Nice, France.
10. Klaić, B. *Rječnik stranih riječi*. Zagreb: Matica Hrvatska; 1978.
11. Oluić-Vuković V. Vremenska komponenta u informetrijskim razdiobama. Zagreb: Sveučilište u Zagrebu, Filozofski fakultet, doktorska disertacija; 1999.
12. Rousseau R. Relations between continuous versions of bibliometric laws. *Journal of the American Society for Information Science* 1990; 41 (3): 197-203.
13. *Sanguanpong, S., Warangrit, S.* Facts about the Thai Web. Department of Computer Engineering, Kasetsart University Bangkok, Thailand.
14. Tuđman M. (urednik). *Modeli znanja i obrada prirodnog jezika*. Zagreb: Zavod za informacijske studije; 2003.
15. Tuđman M., Nives M., Boras D. Vocabulary size prediction of Croatian texts. Proceedings of the 25th Int. Conf. *Information Technology Interfaces* ITI 2003, June 16-19, 2003, Cavtat, Croatia.
16. Tuđman M., Boras D., Mikelić N. *Heapsov zakon i određivanje veličine vokabulara tekstova na hrvatskom jeziku*. Dokumentacija. Filozofski fakultet, Odsjek za informacijske znanosti, Zagreb, 2004.

17. Turner G. R. Relationship Between Vocabulary, Text Length and Zipf's Law; 2001.
<http://www.btinternet.com/~g.r.turner/ZipfDoc.htm> [02/20/2003]
18. Ure J. Lexical density and variety differentiation. In: Perren G, Trim J, editors. Applications of Linguistics: Papers From the 2nd AILA Congress. Cambridge: Cambridge University Press; 1971. p. 443-52.
19. Urzua C.M. A simple and efficient test for Zipf's law. Economics Letters 66 (2000) 257-260.