

Web-corpusen Ataria



Igor Leturia, Iñaki San Vicente, Iker
Manterola, Antton Gurrutxaga

IEB 2013


Miramon, 2013ko maiatzaren 8a

Edukia


- ZERGATIK egin dugu?
- ZER da?
- ZENBAT du?
- NOLA egin dugu?
- ZERTARAKO balio dezake?
- Hurrengo urratsak

ZERGATIK egin dugu ?


Zenbait hizkuntzatako testu-corpus nagusiak




Zenbait hizkuntzako testu-corpus nagusiak



Zenbait hizkuntzatako testu-corpus nagusiak



Zenbait hizkuntzako testu-corpus nagusiak



ZERGATIK egin dugu?

- Ikuspegি “praktikoaz” gain...
 - Ikuspegи linguistikoa
 - Internet ezin ukatuzko errealitate "linguistikoa" ere bada
 - Interneten BAKARRIK argitaratzen diren testuak gero eta ugariagoak dira, eta ezaugarri bereziak dituzte
 - Interneteko testu asko ez dira "diskurtso kontrolatuak", bat-batekoak baizik; hizkuntzaren erabilera erreala islatzen dute
 - Interesgarria da webaren alderdi linguistiko bereziak aztertzea

- Zer da Web-corpuseن Ataria?
 - Webetik automatikoki osatutako euskarazko corpuseن kontsulta aurreratua
 - Elhuyar Fundazioko hizkuntza-teknologien I+G taldeak egindako lanaren emaitza
 - Hiru atal:
 - Euskarazko web corpus elebakarra
 - Euskara-Gaztelania web corpus paraleloa
 - Hitz-konbinazioen kontsulta

Galdera

Zer	Aukerak	Bilatu	Kategoria
Lema	Da	xedapen	<input type="button" value="▼"/>
Dist.	Non	Zer	Aukerak Bilatu
<input type="button" value="▼"/>	<input type="button" value="▼"/>	<input type="button" value="▼"/>	<input type="button" value="▼"/>
Dist.	Non	Zer	Aukerak Bilatu
<input type="button" value="▼"/>	<input type="button" value="▼"/>	<input type="button" value="▼"/>	<input type="button" value="▼"/>

Emaitzak	Testuinguruak eta kopuruak
Ordenatu honen arabera	Dokumentua
Kopuruak	Gehienez %
Forma	10
Lema	<input type="button" value="▼"/>
Kategoria	<input type="button" value="▼"/>
Lema eta kategoria	<input type="button" value="▼"/>


Bilaketa arrunta

→ Bilatu ✖ Garbitu

Emaitzak: 13486

Kopuruak

Forma	Kop.
xedapen	7041
xedapenAK	2668
xedapenA	1158
xedapenen	736
xedapenetan	463
xedapenek	380
xedapenei	181
xedapenean	176
xedapenetik	151
Beste guztiek	532
Guztira	13486



Denak (13486)

- https://www6.euskadi.net/u81-0003/eu/contenidos/autorizacion/2216/eu_4901/eu_17719.html (1)
...datzen ere procedura administratiboak erregulatzetan dituzten xedapen arautzaleak, eta, ondorioz, ezin ditu sortu berariazko Ara...
- http://www.kutxa.net/wkn_corporativo/2009/informe_financiero/eu/memoria_consolidada_02.htm (1)
...kal, Administratiboa eta Ordena Sozialari buruzkoaren, azken Xedapenetako hamaiakarrenak ezartzen duenaren arabera.
- http://www.euskadi.net/cgi-bin_k54/ver_e?CMDVERDOC&ASSEB03D&DOCH000038101&CONF/config/k54/bopv_e.cnf (2)
...3. artikuluetan eta artikulu horiekin erlazionatutako beste xedapenetan ezarritakoarekin bat etorri.
- <https://ssl4.gipuzkoa.net/euskera/gao/2004/02/16/e0401200.htm> (4)
XEDAPEN GEHIARRIAK
XEDAPEN IRAGANKORRA
AZKEN XEDAPENAK
- I. KAPITULUA. BABES-ARAUBIDEAREN XEDAPEN OROKORRAK
<http://www.cgt-lkn.org/laescoba/convenio/Mungia.pdf> (3)
...a jatorria edozein izanik ere. Aplikazio orokreko legezko xedapenak, edo Hitzarmen Kollektiboak, edo banakako kontratuak direla ...
XEDAPENAK
40. artikulua.--Azken xedapenak Hitzarmen hau indarrean dagoen bitartean, bertan itundutako...
<http://www.senado.es/brsweb/CALEX/textos/paisvasco/44/2003/03.pdf> (7)
Bestelako Xedapenak
Xedapen Orokorrak
- Lege honek hojeita bat artikulu ditu, lau xedapen iragankor eta azken xedapen bat. Legeak zehaztu eginen ditu...
... hogeita bat artikulu ditu, lau xedapen iragankor eta azken xedapen bat. Legeak zehaztu eginen ditu aurrezki-kutxen eremuuan jar...
Aurrezki-kutxek lege honetako xedapenetan egoritu beharko dituzte beren estatutuak eta araudiak, eta ...
XEDAPEN
XEDAPENA
- <http://www.innobasque.com/Modulos/DocumentosVisor.aspx?docId233> (3)
Xedapen Orokorrak
- ...azaroaren 26ko 30/1992 Legean zehaztutakoa edo bere ordeko xedapenak ezartzen duena izango da ezarriari. Hiru garren. Aurrekon...
...zarritako mugen barruan. Aipatutako Lega Organiko horren 5. xedapen gehigarriak ezarritakoaren arabera, Unibertsitatea Koordinatzailea...
- <http://www.donostia.org/ordenanzas.nsf/dbda625a50d6b4b841256600044e4ed/b8970ea57f9ec357c12574ea002a49bc?OpenDocument> (2)
...laren Seko Foru Arauean ezarritako prezio publikoek buruzko xedapenekin bat, Donostia Gatzteraren Aterpetxe eta Kanpalekuaren Udal ...
10. art. Azken xedapena
- <http://www.euskadi.net/bopv2/datos/1993/09/9302983a.pdf> (1)
Bestelako Xedapenak
- <http://www.gipuzkoa.net/euskera/gao/2004/12/03/e0411069.htm> (5)
XEDAPEN OROKORRAK
Xedapen Gehiarrak.
- Indargabetzeko Xedapena.
Azkenaurreko Xedapena.
Azken Xedapena.
- http://www.euskara.euskadi.net/r59-euadm2/eu/contenidos/informacion/ohiko_galderak/eu_irati/dekretuari_buruzkoak.html (2)
...tik kentzeko espedientea has daitekeela ondoriozta daiteke. Xedapen honen oinarria 6/1989 Legean daio, 50. artikulan hain zuze...

Galdera

Zer	Aukerak	Bilatu
Lema	Da	<input type="checkbox"/> kedapen
Dist.	Non	Zer
		Aul
Dist.	Non	Zer
		Aul

Bilaketa arrunta

Emaitzak: 13486



Kopuruak

Forma

- xedapen**
- xedapenAK**
- xedapenA**
- xedapenen**
- xedapenetan**
- xedapeneak**
- xedapenei**
- xedapenean**
- xedapenetatik**
- Beste guztiek**

Guztira

Guztien testuinguruak (%)

Web-corpusen Ataria
Corpus paraleloa

Galdera		Babeslea:					
Web-corpusen Ataria Corpus paraleloa		EUSKO JAURLARITZA GOBIERNO VASCO					
		Data Teknologia					
Hasiera	Corpus elebakarra	Corpus paraleloa	Hitz-konbinazioak	Lagunza			
Eranskinak							
Galdera							
Hizkuntza	Zer bilatu	Aukerak	Hitz	Kategoria			
Euskara	Lema	Da	<input type="checkbox"/> likidezia	<input type="checkbox"/>			
Hizkuntza	Zer bilatu	Aukerak	Hitz	Kategoria			
Gaztelania	Lema	Da	<input type="checkbox"/>	<input type="checkbox"/>			
Ordenatu honen arabera							
Maiztasuna							
Bilatu	Garbitu						
Emaitzak: 81 itzulpen-unitate, 10 domeinu							
Euskara							
www.tesoro.es (75)							
likidezia		iturriak	Liquidez	www.cajnavarra.es (27)			
				fuentes			
likidezia		iturriak	Liquidez	www.cajnavarra.es (26)			
				fuentes			
CAN Goreneko likidezia		iturriak	CAN Máxima Liquidez	www.cajnavarra.es (14)			
				fuentes			
Behin pizgarria lortu denean, aurreki plana egiten jarraitza komeni da. Lehen unetik likidezia denu produktu bat izanik, alifik eta luzeena den epea ezartza komeni zaiztu, aurrezten jarraitza nahi baduzu edo zure aurrezkiak eskura izateko unikeri onena aukeratu nahi baduzu, une bakoitzean egon daitekeen zerga abantaila onura aterta baitziezaiekezu.		iturriak	Una vez conseguido el incentivo es recomendable seguir con el plan de ahorro, ya que al tratarse de un producto con liquidez desde el primer momento, conviene establecer un plazo lo más largo posible en caso de que quieras seguir ahorrando o que quieras elegir el momento óptimo para disponer de tu ahorro, pudiéndote beneficiar de las posibles ventajas fiscales del momento.	www.cajnavarra.es (11)			
www.cajnavarra.es (11)				fuentes			
Berankortasun maila murrizten da eta likidezia , gaudimien eta diruzaintza ratioak hobetzen.		iturriak	Se rebaja el nivel de morosidad, las pérdidas y se mejoran los ratios de liquidez, solvencia y tesorería.	www.cajnavarra.es (9)			
www.cajnavarra.es (9)				fuentes			
Ondasuna eskura dago norberaren altxortegia erabil behar izan gabe. Hori dela eta, empresas edo likideziarik galtzen eta errentagarritasun bat lortzen du, altxortegia beste ibertsio batzuetara bideratzean.		iturriak	Al disponer del bien sin necesidad de utilizar tesorería propia, la empresa no pierde liquidez y obtiene una rentabilidad al destinario a otro tipo de inversiones.	www.cajnavarra.es (9)			
www.cajnavarra.es (9)				fuentes			
Zerga abantaila maximoekin, eta berehalako likidezia , lehen ekarpenetik 10 urte igaro eta gero.		iturriak	Con las máximas ventajas fiscales y de liquidez inmediata transcurridos 10 años desde la primera aportación.	www.cajnavarra.es (9)			
www.cajnavarra.es (9)				fuentes			
Aurreikuspen plana (EPSV) bada, gainera, berehalako likidezia du, 10 urteko antzinatasuna betetzen denean. Pentsio planek aparteko Kapitala sortzen dute -erretiratzeagik edo ezintasunagatik ordaintzen duten pentsioa osatzentzen duen kapitala, hain zuzen- eta, partaidea hiltzen bada, beste persona batzuei laguntzen diete.		iturriak	Estamos ante un producto financiero que, además de garantizar ingresos extra a la hora de la jubilación, supone una ayuda eficaz para ahorrar en la declaración de la renta. Si lo que se tiene es un plan de previsión (EPSV), además cuenta con una liquidez inmediata a los 10 años de antigüedad del mismo.	www.cajnavarra.es (8)			
www.cajnavarra.es (8)				fuentes			
Banca Cívica taldea izan zen estreinako erregio arteko integratze-prozesua Espainiako finantza-sistema jasaten ari den sendotza-prozesuaren barruan. Eragiketa aurretenetua da sektorean -lehendabiziko izan zen banku propio operatiboa sortzen, 2010eko ekainetik-, eta egoera sendoa du, likideziarik eta kaudimenari dagokienez, baita balantze santeauta ere.		iturriak	La creación del grupo Banca Cívica fue el primer proceso de integración interregional dentro del proceso de consolidación sectorial que viene el sistema financiero español y es la operación más avanzada del sector -fue el primero en crear un banco propio operativo desde junio de 2010- con una sólida posición en liquidez y solvencia y un balance saneado.	www.kutxa.net (8)			
www.kutxa.net (8)				fuentes			
2011ko ekainaren 21ean, Standard & Poor's rating agentziak A/A-1 kalifikazioa (outlook negative) berretsi do zuxtari, berriro ere emititarean finantz-a-sendotazun, kaudimen eta likideziazatik		iturriak	El 21 de junio de 2011 la agencia de rating Standard & Poor's ha ratificado a kutxa la calificación A/A-1, outlook negative, basada, una vez más, en la fortaleza financiera, la solvencia y la liquidez de la Entidad.	www.segurosagunaro.com (8)			
www.segurosagunaro.com (8)				fuentes			
likidezia : zure dirua (osorik edo haren zati bat) noiztik berreskuratzeko aukera izango duzu, inolako gainordainik eta komisio gehigarrikin GABE.		iturriak	Liquidez: en cualquier momento podrás disponer de tu ahorro, total o parcialmente, SIN ningún recargo ni comisión adicional.	www.segurosagunaro.com (8)			
www.segurosagunaro.com (8)				fuentes			
Erabateko likidezia eskaintzen du, aurreztutako zenbateko edokozun netutan berreskuratzeko aukera baitago.		iturriak	Ofrece plena liquidez, ya que el ahorro constituido está disponible en cualquier momento.	www.cajnavarra.es (7)			
www.cajnavarra.es (7)				fuentes			
Inbertsio fondo bat kontratatzeko dituen alde onagusiak bat, fiskalitate erakargarria izateaz gain, likidezia da. Izen ere, kasu gehienetan, inbertitutako kopurua berehalako erabilgarri izateko aukera ematen baitu.		iturriak	Una de las principales ventajas de contratar un fondo de inversión, además de una atractiva fiscalidad, es su liquidez, ya que permite disponer, en la mayor parte de los casos, de la cantidad invertida de forma prácticamente inmediata.	www.cajnavarra.es (7)			
www.cajnavarra.es (7)				fuentes			
Berehalako likidezia , izateko bidea ematen du, aipatutako dokumentuak endosatuta edo utzita. Epe laburrean amaitzen da, eskuarki, 90 egun igaro baino lehenago.		iturriak	Permite liquidez inmediata, mediante el endoso o cesión de los documentos citados, con vencimiento a corto plazo; habitualmente inferior a 90 días.	www.cajnavarra.es (7)			
www.cajnavarra.es (7)				fuentes			
Aseguru hori kengaria da zergiei begira eta aukera ematen do banku finantzaketa hobea izateko: likidezia , gaudimien eta diruzaintza ratioak hobetzen ditu.		iturriak	Este seguro es deducible fiscalmente y permite una financiación bancaria más favorable: mejores ratios de liquidez, solvencia y tesorería.	www.cajnavarra.es (5)			
www.cajnavarra.es (5)				fuentes			
CAN GORENEKO LIKIDEZIA CENek azaldu du finantzatze lerro bat izatea interesatzen zaiola, epe labur, ertain eta luzezko finantzak berakontzak alabidetzen duena. Horregatik, CANek CAN GORENEKO LIKIDEZIA finantzatze lerro berria sortu du. Gainera, empresaren aktibokoian likidezia sortzeko aukera ematen du lerro horrek.		iturriak	CAN MAXIMA LIQUIDEZ: en base al interés manifestado por CEN en la disposición de una línea de financiación que posibilita resolver tanto las necesidades financieras a corto, medio y largo plazo, CAN crea la línea de financiación CAN MAXIMA LIQUIDEZ que además permite generar liquidez con los activos de la empresa.	www.cajnavarra.es (5)			
				fuentes			

Galdera


Zer	Aukerak	Bilatu
Lema	Da	<input type="checkbox"/> kedapen
Dist.	Non	Zer
<input type="checkbox"/>	<input type="checkbox"/>	Aul
Dist.	Non	Zer
<input type="checkbox"/>	<input type="checkbox"/>	Aul

Bilaketa arrunta

Emaitzak: 13486

Kopuruak

Forma	Forma
<input checked="" type="checkbox"/> kedapen	
<input checked="" type="checkbox"/> xedapenAK	
<input checked="" type="checkbox"/> xedapena	
<input checked="" type="checkbox"/> xedapen	
<input checked="" type="checkbox"/> xedapenetan	
<input checked="" type="checkbox"/> xedapene	
<input checked="" type="checkbox"/> xedapenei	
<input checked="" type="checkbox"/> xedapenean	
<input checked="" type="checkbox"/> xedapenetik	
<input checked="" type="checkbox"/> Beste guztiek	
Guztira	



Guztien testuinguruak basa
Berankortasun maila murritz
Ondasuna eskura dago norbe
ez du **likideziarik** galzten &
batzuetara bideratzean.
Zerga abantaila maximoekin,
gero.
Aurreikuspen plana (EPSV) i
betetzen denean. Pentsio p
ezintasunagotik ordaintzen
hiltzen bada, beste persona
Banka Cívica taldea izan
finantz-sistema jasaten ar
sektorean -lehenadibiziko-
eta egoera sendoa du, **likide
zia** 2011ko ekainaren 21ean,
negatibo berretsi dio kuxi
likideziagatik.

likidezia: zure dirua (osor
duzu, inolako gainordainik e
rrobateko likidezia eskauntz
aukera baitago.

Inbertsio fondo bat kontrat
izateaz gain, **likidezia** da,
erabilgarri izateko aukera en

Berehalako **likidezia**, izatez
utzita. Epe laburrean amaitza
Aseguro hori kengaria da;
izateko: **likidezia**, gaudimena

CAN GORENEKO **LIKIDEZIA**
epe labur, ertain eta lueraz
CANek CAN GORENEKO **LIK
AKTIBOKIN likidezia sortzeko**

Hasiera

Corpus elebakarra

Corpus paraleloa

Hitz-konbinazioak

Lagunza

Eranskina

Galdera

Hizkuntza

Zer bilatu

Euskara

Lema

Dist.

Non

Zer

Aul

Zer

ZENBAT du?

- Zenbat du euskarazko web-corpus elebakarrak?
 - Hitzak: 125 milioi inguru
 - Dokumentuak: 82 mila inguru
 - Domeinu ezberdinak: 6.206
- Testu-motak: periodistikoa, literatura, akademikoa, hezkuntza, webeko berezkoak (blogak, foroak...), administratiboa...

Domeinua	Dokumentuak	Hitzak
www.argia.com	2.886	4.026.006
www.zientzia.net	2.353	3.093.083
www.euskomedia.org	757	2.638.731
eibar.org	1.299	2.538.105
eu.wikipedia.org	2.422	2.281.205
www.soziolinguistica.org	690	2.102.094
www.ikasbil.net	1.220	1.932.899
klasikoak.armiarma.com	905	1.930.030
www.uztaro.com	407	1.916.843
www.euskonews.com	1.354	1.743.869
www.euskadi.net	775	1.683.893
www.armiarma.com	600	1.601.705
www.jakingunea.com	581	1.583.140
revista.consumer.es	1.518	1.459.116
paperekoa.berria.info	1.769	1.448.311
www.euskaltzaindia.net	563	1.388.255

ZENBAT du?

- Zenbat du euskara-gaztelania web-corpus paraleloak?
 - Hitzak: 18 milioi inguru
 - Segmentuak: 1,2 milioi inguru
 - Dokumentuak: 174 mila inguru
 - Domeinuak: 84
- Testu-motak: administratiboak, erakundeen webguneak, turismoa, kultura, albisteak, enpresak, alderdi politikoak...

Domeinua	Dokumentuak	Segmentuak	Hitzak
www.euskonews.com	3.444	165.736	3.014.432
www.euskalkultura.com	9.888	98.042	1.679.440
www.hiru.com	20.116	104.738	1.418.600
www.donostia.org	8.594	84.502	1.379.709
www.euskomedia.org	1.356	41.998	998.369
www.ermua.es	12.930	66.886	971.038
www.3digitala.com	16.888	66.028	829.583
www.turismoa.euskadi.net	4.528	41.530	513.617
web.bizkaia.net	3.946	31.126	398.359
www.euskadi.net	2.884	28.604	355.664
www.eusko-ikaskuntza.org	4.426	16.544	306.171
www.ibaizabal.com	5.252	27.820	305.847
www.pasaia.net	1.716	22.664	291.672
www.mondragon.edu	2.772	20.812	286.619
www.lezo.net	892	15.598	279.035
www.euskara.euskadi.net	898	16.584	256.107
www.catedralvitoria.com	2.548	14.040	251.208
www.aralar.net	1.458	12.124	247.887
www.guggenheim-bilbao.es	3.036	17.304	235.906
www.basqueresearch.com	3.836	15.980	234.674

ZENBAT du?

- Zenbat du konbinazioen atalak?
 - Konbinazioak: 133 mila inguru
 - Agerpenak: 10 milioi inguru


Mota	Kopurua	1. osagaiak	2. osagaiak
IZE-ADI	71.550	8.199	1.528
IZE-ADJ	27.931	4.797	2.782
IZE-IZE	33.759	7.067	7.002

NOLA egin dugu euskarazkoa?

XX. Mendeko Corpus
Estatistikoko maitzasun
handieneko 2.000 hitzak

Ausazko bikote-konbinazioak bidali
web-bilatzaile baten APIari,
sorkuntza morfologiko bidezko
hedapena eginez, eta hizkuntza
iragazteko hitzkin batera

Euskarazko web-corpus gordin
erredundantea



NOLA egin dugu euskarazkoa?



- **Luzera-iragazkia:** laburregiak eta luzeegiak iragazi, errore-orriak, testu gutxi dutenak eta spama saihesteko
- **Hizkuntza-iragazkia:** Langid hizkuntza-detektatzailea paragrafo mailan, testu elebidunetako zati ez euskarazkoak kentzeko
- **Orrien garbiketa:** nabigazio-menuak, oin-oharrak... kentzeko
- **Errepikatuen iragazkia:** ia berdinak diren dokumentuak iragazteko (agentziako berriak, lizenzia libredun testuen kopiar...)
- **Barne-hartze iragazkia:** blog edo komunikabide bateko artikulu bat osorik orri nagusian agertzen denean bi bider ez sartzeko

NOLA egin dugu paraleloa?

Euskarazko hitz-konbinazioak



Euskarazko edukia duten domeinuak:

www.elhuyar.org

www.zientzia.net

Eduki elebiduna duten domeinuak



eu



es



Domeinuak eduki elebiduna du?
Alt testuak, Hizkuntza arteko estekak, Combo egiturak,...


NOLA egin dugu paraleloa?

Eduki
elebiduna
duten
domeinuak



A large stack of books, with many pages flying off the top, symbolizing knowledge or education.

eu-es dokumentu paraleloen bilduma



Elkarren itzulpen diren esaldiak parekatu: Hunalign+Postprozesua

eu-es corpus
paralelo garbia

elhuyar
Hizkuntza eta Teknologia


Elkarren itzulpen diren dokumentuak aurkitu

- **Dokumentuen ezaugarriak bildu:**
Hizkuntza (text_cat), URLa, luzera, hitz kopurua...
 - **Elkarren itzulpen diren dokumentuak lotzeko:**
luzera/hizkuntza heuristikoak, URLen arteko antzekotasuna, esteka-jarraitzailea, edukiaren azterketa (hizkuntza artekoan)

San Vicente, I. & Manterola, I. (2012). "PaCo2: A Fully Automated tool for gathering Parallel Corpora from the Web". In *Proceedings of the 8th international conference on Language Resources and Evaluation, LREC'12*. 23-25 May, Istanbul, Turkia.

NOLA egin dugu hitz-konbinazioen erauzketa?


Euskarazko web-
corpus etiketatua



- Corpus elebakar etiketatuaren irteera moldatu
- Interesatzen zaigun informazioa atxiki
- Analisi batzuk testuinguruaren arabera eraldatu


- egunean egun IZE ARR INE NUMS
- dokumentatutako_dokumentatu_ADI_SINPART_GEL_0 grafien_grafia_IYE_ARR_GEN_NUMP
- indar_indar_IYE_0_0 armatuak_armatu_ADI_SINPART_ABS_NUMP → indar_indar_IYE_0_0 armatuak_armatu_ADJ_ADIPART_ABS_NUMP
- ...

Bigrama-erauzketarako
web-corpus etiketatua



NOLA egin dugu hitz-konbinazioen erauzketa?

Bigrama-erauzketarako
web-corpus etiketatua



Bigrama-erauzketa



Bigrama-erauzketa +
informazio estatistikoa

Patroi morfosintaktiko batzuk betetzen dituzten
IZEADI, IZEADJ, IZEIZE agerkidetzetik bigramak
sortu ($w=\pm 1; f > 10$)

- IZEADI: izenaren forma_lema_kat_azpik_kasua_mugat; aditzaren lema (+aspektua, flexioa...)
- Izenaren formak normalizatu, f handienekora
- IZEIADJ: iz.Ø+izond. sintagmak edo sintagma-zatiak
- IZEIZE: iz. Ø +iz. sintagmak edo sintagma-zatiak (elkartea)

Terminal — ssh — 178x57														
id	l1	l2	f	f1	f2	N	am.t.score	am.log.likelihood	am.MI	am.MI3	am.chi.squared	am.z.score		
10443	nahi_nahi_IZE_ARR_ABS_MG	ukan_ADI	115928	143684	426774	2817230	276.5541924	333326.1246	0.72640428	10.85478097	505872.384	638.237604		
2328	behar_behar_IZE_ARR_ABS_MG	ukan_ADI	102522	214368	426774	2817230	218.7697593	142397.6740	0.49928146	10.52091560	192738.624	388.712066		
13257	uste_uste_IZE_ARR_ABS_MG	ukan_ADI	56044	56371	426774	2817230	200.6644221	214195.3541	0.81709774	10.31415599	317803.094	514.066433		
2315	behar_behar_IZE_ARR_ABS_MG	izan_ADI	99512	214368	629138	2817230	163.6992368	66382.3628	0.31779189	10.31354280	77627.050	236.016626		
11169	parte_parte_IZE_ARR_ABS_MG	hartu_ADI	18292	22636	93411	2817230	129.6985361	106445.8006	1.38688579	9.91140818	427467.972	640.291844		
8823	kontuan_kontu_IZE_ARR_INE_NUMS	hartu_ADI	14494	19298	93411	2817230	115.0761443	79664.0841	1.35510024	9.67747675	312392.106	547.690769		
226	dhal_dhal_IZE_ARR_ABS_MG	izan_ADI	22077	27128	629138	2817230	107.1804326	43204.0911	0.56159867	9.24947878	55065.450	205.806991		
5239	ezin_ezin_IZE_ARR_ABS_MG	izan_ADI	26592	48587	629138	2817230	96.5327738	24447.4904	0.38930732	9.23880931	29928.507	151.122259		
9137	lan_lan_IZE_ARR_ABS_MG	egin_ADI	18584	55657	300597	2817230	92.76067192	21256.9122	0.49545707	9.03373546	30750.560	164.093893		
2365	behera_behe_IZE_ARR_ALA_NUMS	utzi_ADI	8278	16263	28987	2817230	89.1443575	55953.1793	1.69434379	9.53019464	399519.065	626.997424		
3178	deia_dei_IZE_ARR_ALS_NUMS	egin_ADI	9791	11233	300597	2817230	86.3866814	35812.4581	0.91216895	8.89382386	69232.961	248.191952		
6904	hitz_hitz_IZE_ARR_ALS_NUMS	egin_ADI	11337	20466	300597	2817230	85.9662667	24982.5302	0.71530284	8.82429913	43264.120	195.875215		
4103	erabakia_erabaki_IZE_ARR_ABS_NUMS	hartu_ADI	7961	10511	93411	2817230	85.3184028	43424.5220	1.35874787	9.16068312	172623.824	407.771297		
5248	ezin_ezin_IZE_ARR_ABS_MG	ukan_ADI	19090	48587	426774	2817230	84.8953307	17026.5353	0.41391020	8.97552285	22416.856	136.722157		
9036	lagun_lagun_IZE_ARR_ABS_MG	hil_ADI	6423	17523	21605	2817230	78.4668589	41778.0415	1.67939749	9.29487334	298416.712	542.481604		
4822	espero_espero_IZE_ARR_ABS_MG	ukan_ADI	9651	13323	426774	2817230	77.6951952	22108.4695	0.67959464	8.64873927	34180.878	169.899258		
5308	falta_falta_IZE_ARR_ABS_MG	izan_ADI	10739	12823	629138	2817230	75.9830069	21979.0205	0.57384742	8.63577511	27991.057	147.109320		
10516	neurriak_neurri_IZE_ARR_ALS_NUMP	hartu_ADI	6364	9912	93411	2817230	75.6549226	31088.8866	1.28699316	8.89445350	115038.258	332.915313		
1664	aurerria_aurrie_IZE_ARR_ALA_NUMS	egin_ADI	8739	17482	300597	2817230	73.5289588	17027.2496	0.67070829	8.55363176	28531.913	159.152166		
9927	martxan_martxa_IZE_INE_NUMS	jarri_ADI	5316	7367	47148	2817230	71.2192919	35447.6728	1.63465333	9.08582328	223009.393	467.657775		
2422	berri_berri_IZE_ARR_ABS_MG	eman_ADI	5480	10005	110195	2817230	68.7405445	22355.8254	1.14622388	8.62378500	69107.205	257.231949		
11221	partido_partido_IZE_ARR_ABS_MG	jokatu_ADI	5036	14837	36802	2817230	68.2922156	25847.8516	1.42411469	8.82828613	126106.546	351.907519		
341	okordioa_okordio_IZE_ARR_ABS_NUMP	lortu_ADI	4921	11638	33380	2817230	68.1841466	28691.4956	1.55251098	8.93661771	168597.863	407.322970		

ZERTARAKO balio dezake?

- <http://webcorpusak.elhuyar.org>

Hurrengo urratsak

- Euskarazko web-corpus elebakarrean
 - Handitu crawling metodoa erabiliz (bilatzaileetatik ezin da askoz gehiago lortu) eta online jarri
 - Corpuseko testuak karakterizatu (eremua, generoa...)
- Euskara-gaztelania web-corpus paraleloan
 - Esalditik beherako unitate-mailan parekatu (hitzak, terminoak, fraseologia...)
- Hitz-konbinazioak
 - Idiomatikotasuna karakterizatzeko teknika aurreratuak (konposisionaltasuna)
 - Konbinazio-mota gehiago: IZLG+IZE, ADB+ADI...
 - Patroi morfosintaktikoak (argumentuak, azpikategoria...)
 - Fraseologia elebiduna

Web-corpusen Ataria



Eskerrik asko!

Web-corpusen Ataria



Igor Leturia, Iñaki San Vicente, Iker
Manterola, Antton Gurrutxaga

IEB 2013

Miramon, 2013ko maiatzaren 8a