

Corpus Portal for Search in Monolingual Corpora

Uwe Quasthoff, Matthias Richter, Chris Biemann

NLP Group, University of Leipzig - <http://corpora.uni-leipzig.de>



WORTSCHATZ Word: case sensitive search

term: Genua
number of occurrences: 2624
class of frequency: 12 (i.e. der has got about 2² the number of occurrences than the selected word.)
description:
 Hafenstadt in Italien
 Hafenstadt am Mittelmeer
 Hafenstadt in Norditalien
 italienischer Überseehafen
 Stadt in Italien
 Universitätsstadt in Italien
grammatical data: Wortart: Eigenname

relations to other words:
 • see also: [Schiller](#)

links to other words:
 • ist ein(e) [Stadt](#)
 • Teilwort von: [Sampdoria Genua](#), [FC Genua](#), [Golf von Genua](#)

example(s):
 Zu diesem Zeitpunkt wusste er noch nicht, dass Pro Recco **Genua** gegen Barcelona 11:10 gewonnen hatte, und die Spandauer damit ohnehin am 16. und 17. Mai das Halbfinale gegen Honved Budapest bestritten hätten. (source: [Der Spiegel ONLINE](#))
 Wasserfreundliche Spandau - Partizan Belgrad 6:4 (1:1, 1:1, 3:1, 1:1), **Genua** - Barcelona 11:10. Spandau und Genua für die Finalrunde qualifiziert. (source: [Der Spiegel ONLINE](#))
 Dass seinem Team möglicherweise sogar eine Niederlage gegen Belgrad, den Tabellenletzten der Blauen Gruppe, nicht schaden würde, wenn CN Barcelona zur gleichen Zeit in **Genua** gewinnt, interessiert den Berliner Coach nicht. (source: [Der Spiegel ONLINE](#))
[more examples](#)

significant cooccurrences of Genua:
[in](#) (425), [nach](#) (167), [von](#) (165), [Demonstranten](#) (163), [Venedig](#) (148), [Globalisierungsgegner](#) (140), [Mailand](#) (137), [Engel](#) (135), [Seattle](#) (133), [italienischen](#) (132), [Rom](#) (119), [Neapel](#) (116), [Göteborg](#) (108), [Italien](#) (104), [Fiesco](#) (95), [Ausschreitungen](#) (91), [italienische](#) (87), [Florenz](#) (83), [Carlo](#) (83), [Weltwirtschaftsgipfel](#) (82), [Pisa](#) (80), [Globalisierungsgegner](#) (73), [Turin](#) (73), [Juli](#) (70), [Gipfel](#) (69), [Henker](#) (68), [Giuliani](#) (66), [Doria](#) (60), [Demonstrant](#) (59), [Protesten](#) (57), - (54), [SS-Chef](#) (53), [Recco](#) (53), [Polizei](#) (52), [Globalisierungskritiker](#) (51), [Hafenstadt](#) (49), [G](#) (49), [Erschießung](#) (48), [Krawallen](#) (44), [Attac](#) (43), [Barcelona](#) (43), [Palermo](#) (43), [Italiens](#) (42), [Bologna](#) (42), [Marseille](#) (40), [Krawalle](#) (39), [SD](#) (39), [Livorno](#) (38), [gewalttätigen](#) (37)

cooccurring multi words:
[La Spezia](#) (54)

significant left neighbours of Genua:
[Recco](#) (42), [Hafenstadt](#) (22), [Venedig](#) (13), [südlich von](#) (12), [zweites](#) (9), [Turin](#) (9), [Seestädte](#) (8), [Samp](#) (8), [Marseille](#) (7), [Republik](#) (6), [Heimatstadt](#) (6), [Göteborg](#) (6), [Florenz](#) (5), [IM](#) (4), [Hilf](#) (4), [zündete](#) (3), [murmelt](#) (3), [Quebec](#) (3)

significant right neighbours of Genua:
[La Spezia](#) (17), [Dionigi Tettamanzi](#) (15), [Friedrich](#) (14), [Mailand](#) (10), [zusammenschließen](#) (9), [Neapel](#) (8), [ein Jahr danach](#) (6), [Italien](#) (6), [Resistance](#) (5), [vorbereiten](#) (4), [versammelten](#) (4), [verpachtet](#) (4), [passten](#) (4), [frei sein](#) (4), [erschossenen](#) (4), [aufhalten](#) (4), [Social](#) (4), [Pisa](#) (4), [Francesco](#) (4), [riestet](#) (3), [in Abwesenheit](#) (3), [gereist](#) (3), [festgenommenen](#) (3), [Florenz](#) (3)

Corpora and Sizes

Language	size(sentences)	origin
Catalan	10 M	web
Danish	3 M	web
Dutch	1 M	newspapers
English	10 M	newspapers
Estonian	1 M	newspapers
Finnish	3 M	web
French	3 M	newspapers
German	30 M	newspapers
Icelandic	1 M	newspapers
Italian	3 M	newspapers
Japanese	300 k	web
Korean	1 M	newspapers
Norwegian	3 M	web
Sorbian	300 k	newspapers
Spanish	1 M	web
Swedish	3 M	web
Turkish	1M	web

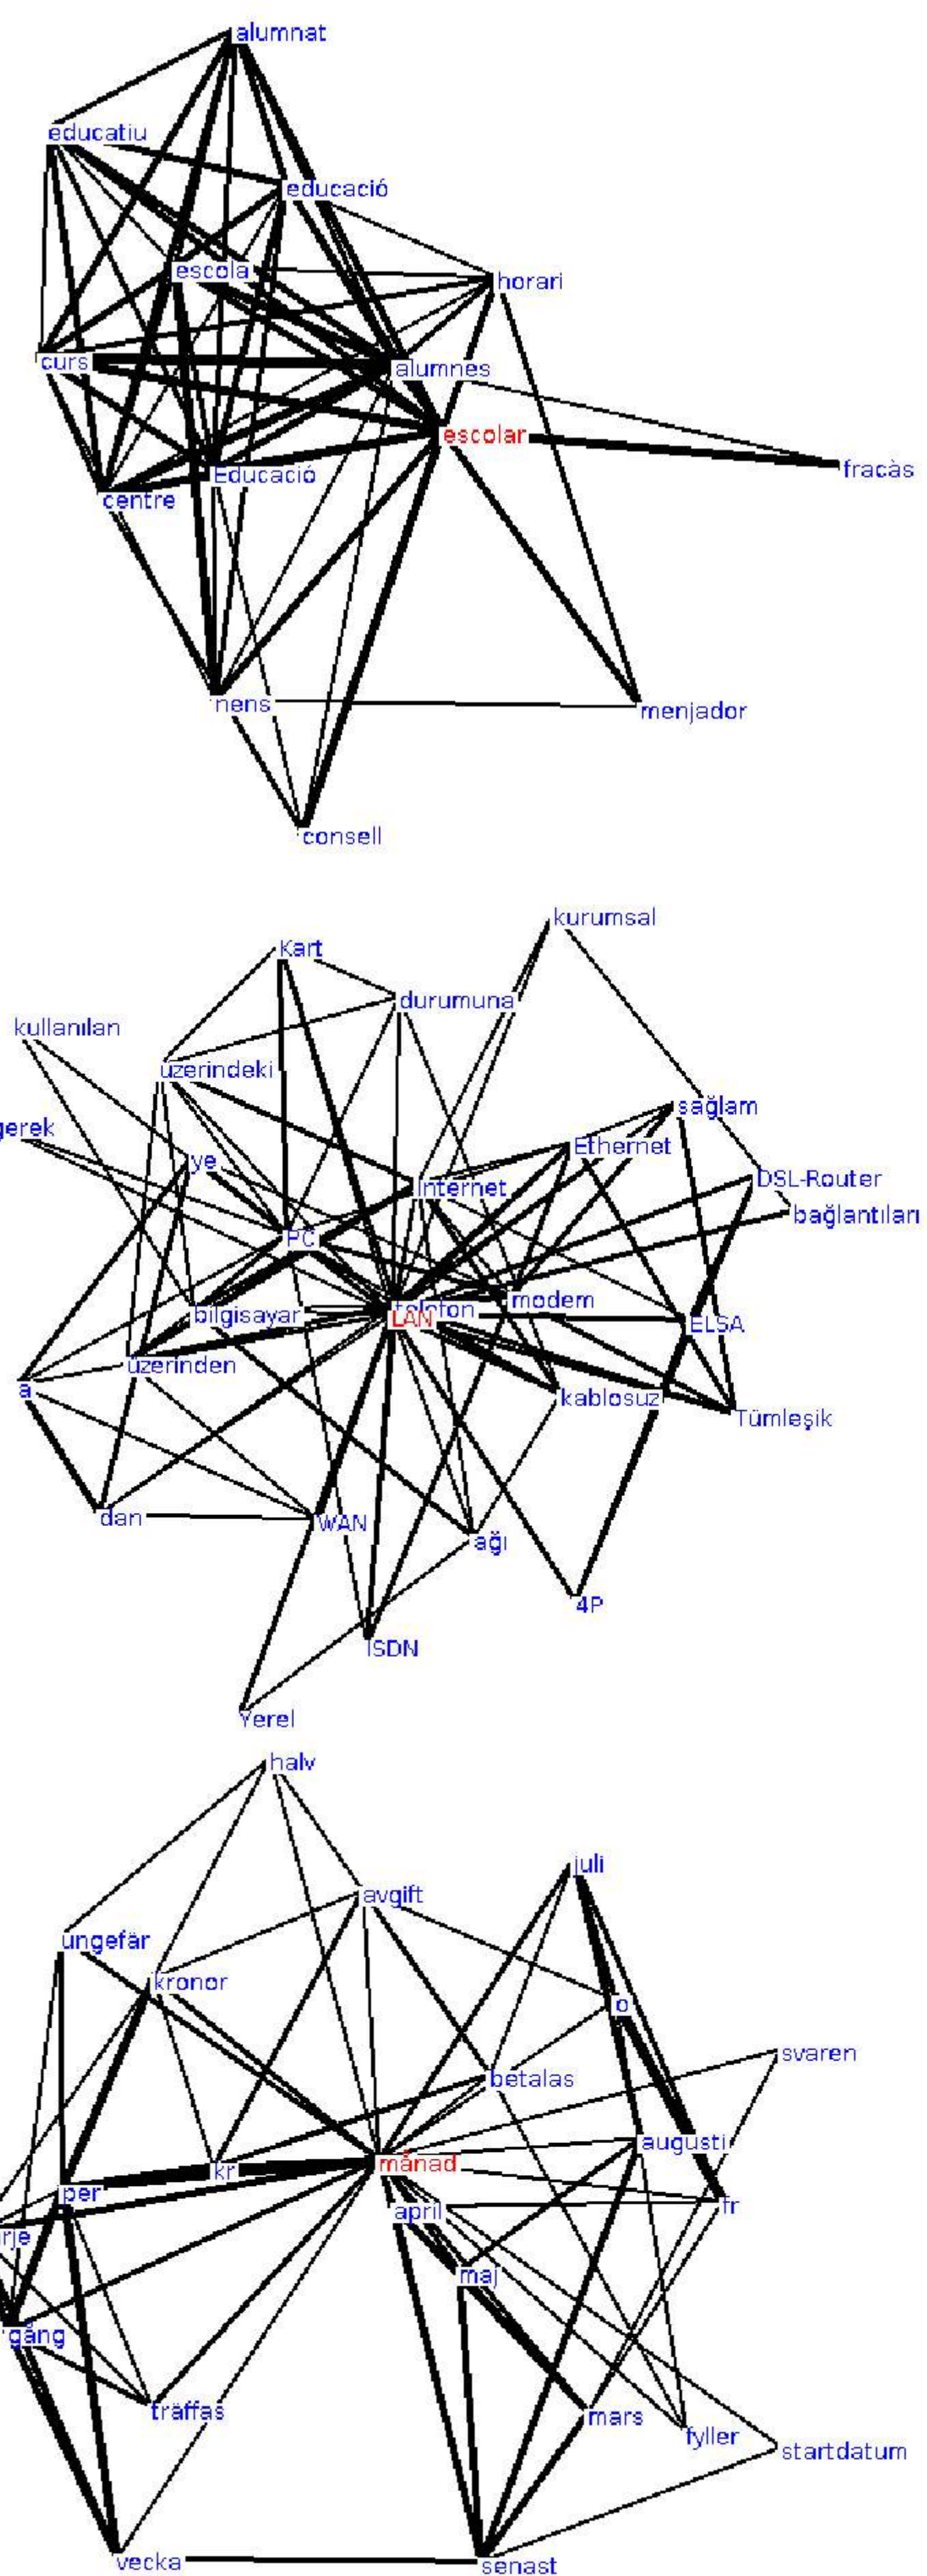
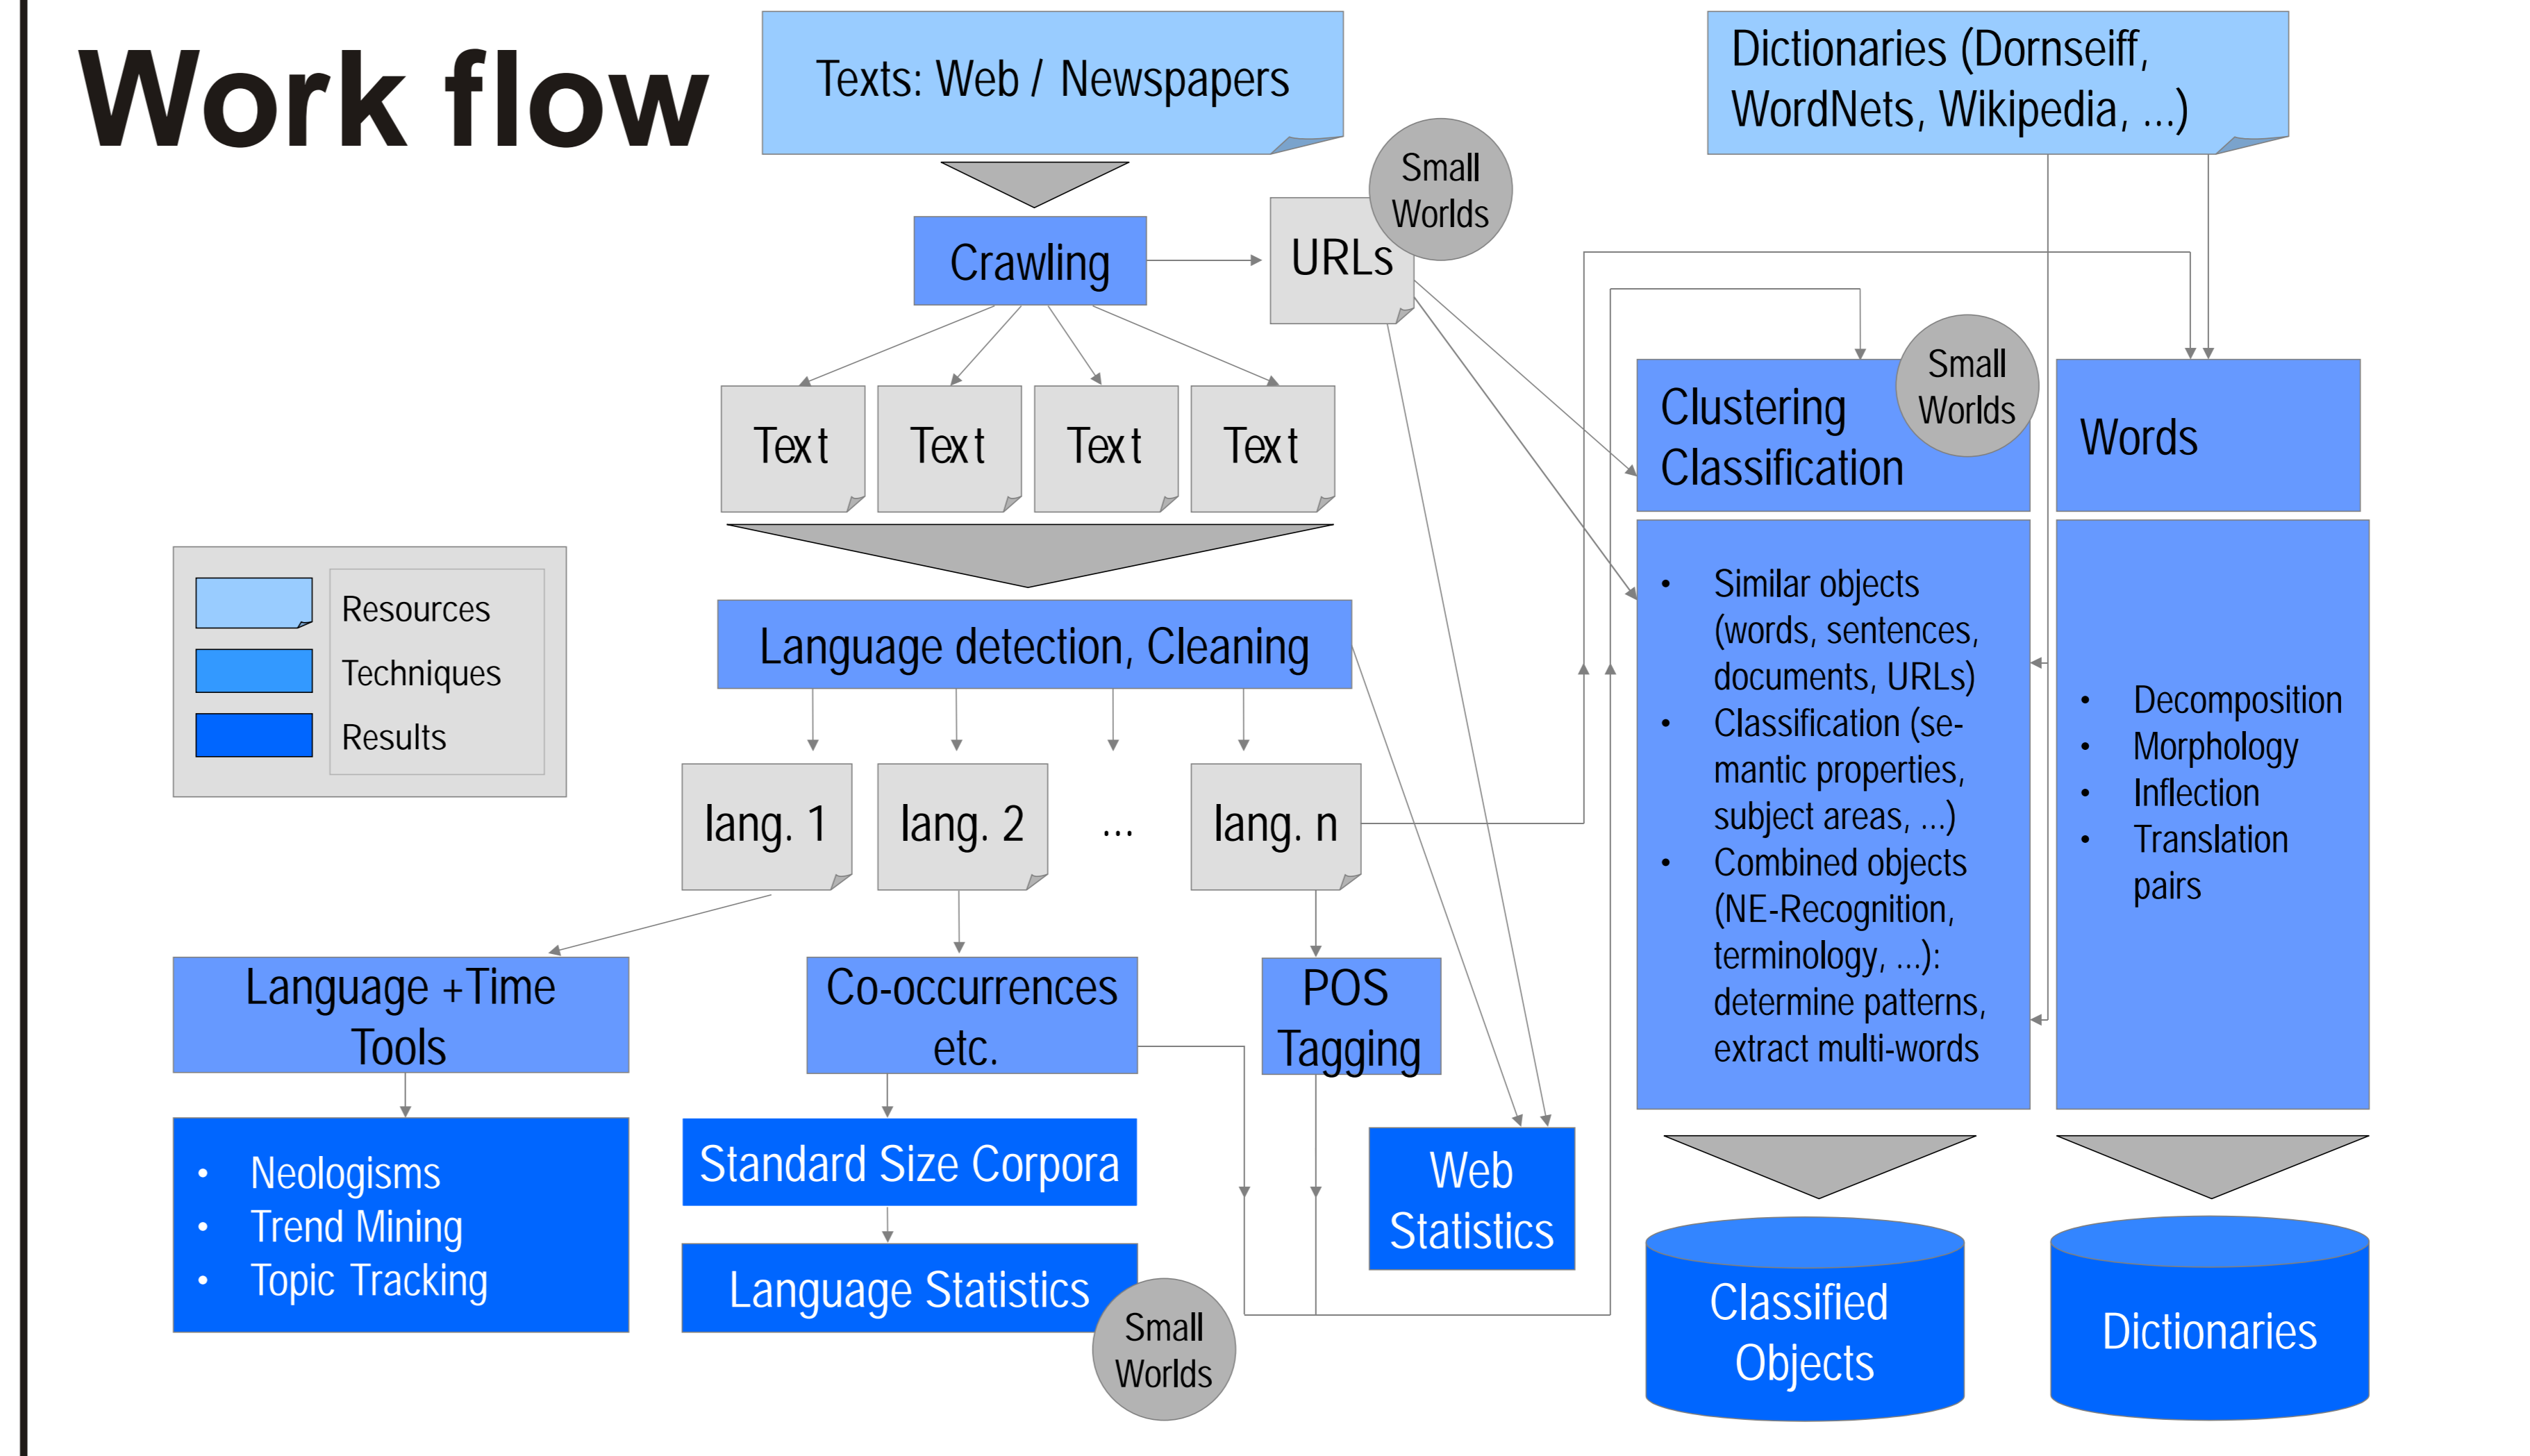
Application Areas

- preparing monolingual dictionaries
- researching linguistic questions
- comparing different languages on a statistical basis
- parameterizing language models e.g. for speech recognition
- expanding queries with statistically similar words
- extracting significant terms from documents by comparison against a reference corpus
- selecting balanced word sets for experiments, e.g. in psycholinguistics

Features

- uniform format and web interface for all corpora
- comparable data sets for different languages
- corpora in several pre-defined sizes
- statistical information including co-occurrence data
- standardized visualization of co-occurrence data free of charge
- access to a collection of linguistic resources free of charge
- seamless integration into applications via SOAP-based Web Services

Work flow



Free DVD!