



Språkbanken's infrastructures for corpora and lexicons

EUROPEAN
NETWORK OF
e-LEXICOGRAPHY

Elena Volodina & Ildikó Pilán
COST ENeL WG3 meeting
Vienna, 12 February 2015



KORP & KARP origin

SweFN++ (2009-2015), a project where one of the objectives is to create, curate, and integrate free Swedish lexical resources --> for researchers and language technology applications

META-NORD (2011-2013), a project aiming at establishing an open linguistic infrastructure in the Baltic and Nordic countries.

<http://spraakbanken.gu.se/korp>
<http://spraakbanken.gu.se/karp>



Architecture principles

Front-end (user interface): search, present, edit



The screenshot shows a search interface with the following elements:

- Simple, Extended, Editor tabs (Extended is selected)
- Search bar: tsunami (substantiv)
- Hits per page dropdown: 25
- Text snippet: "kan idag verkligen inte fatta att det va

Back-end (web services): select from databases, deliver in machine-readable format




Databases: access to corpora and lexicons



```
"Lemma": {  
    "FormRepresentation": {  
        "feat": [  
            {"att": "lemgram",  
             "val": "huvuddrag..nn.1"},  
            {"att": "partOfSpeech",  
             "val": "nn"},  
            {"att": "paradigm",  
             "val": "nn_6n_bord"}  
        ]  
    }},
```



Secret of KORP-2-KARP bi-directionality





KORP - the corpus infrastructure of SB

- **8,5 billion words** new and old texts – downloadable, scrambled
- **KWIC** vs **context** display
- Linguistic **annotation**: POS, lemgrams, msd, dependencies ...
- **Statistic** functions: pie charts, word lists, trend diagrams ...
- **Word pictures**
- **Save** or **bookmark** searches
- Different **views**: modern, parallel, Old Swedish ...



Enkel

Utökad

190 av 197 korpusar valda — 8,49G av 8,50G token

1850 1900 1950 2000

 Markera alla Avmarkeraäven som förläder efterle

KWIC: träffar per sida: 25

KWIC

Statistik

Antal träffar: 815

Föregående

1

2

3

a fel hur de än gör: de förvänt
v i Iris som en "extremt farlig
veckan, enligt den tyska nyh

u tillbaka i äventyrsfilmen nä

n är oron stor i en del EU-län

Tv-kändisar, intelle

ra städer vid Nordsjön och Ö

ar tvingat fram öppningar av

- Akademiska texter (2)
- August Strindberg (2)
- Finlandssvenska texter (56)
- Skyddade korpusar (7)
- Medicinska texter (12)
- Skönlitteratur (6)
- Sociala medier (60)
- Tidningstexter (37)
- Tidskrifter (1)
- Dramawebben (demo)
- LäSBarT - Lättläst svenska och barnbokstext
- PAROLE
- Psalmboken (1937)
- SNP 78-79 (Riksdagens snabbprotokoll)
- SUC 2.0
- SUC 3.0
- SALT svenska-nederländska
- Europarl svenska
- Svenska partiprogram och valmanifest 1887-2010
- Svensk förfatningssamling
- Svenskt frasnät (SweFN)
- Svenska Wikipedia (januari 2015)

rdbild

ontext

GP 2001

I dag väntas en
ts oemotståndliga
orsaka livshotande
vakueras sedan en
det handlar om en
en jättekondor, en
are besatta av den
ar slussarna för en

flovåg flovåg flovågor flovåg flovåg flovåg flovåg flovåg flovåg

nå Jakutsk
", men om de i stället överlever o
och lerskred i bergig terräng.
från Wisla närmade sig.
av privata alternativ.
och en jaguar.
som åter skulle hemsöka jorden.
av arbetslösa invandrare.

GP 2002

v som en fascistisk
ler dukade under i flovågor
nad sedan om den
a skyddsvallar mot
ia där försäkrar att
er sedan en enorm
äntades en formlig
vid det är för olöslig

flovåg flovågor flovåg flovågen flovågen flovåg flovåg flovåg flovåg

över Marseille.
av kuler och granater som svept
av prostataremisser som på sena
som de närmaste dagarna vänta
kommer att ha avtagit innan den
sköljde med sig bilar, hus och m
nå Prag.
av invandrare Persson är rädd fö



24 of 197 corpora selected — 321.94M of 8.50G tokens

Search history

Simple Extended Advanced Compare 2

ord (noun)

also as initial part final part and case-insensitive

KWIC: hits per page: 25 sort within corpora: not sorted Statistics: compile based on: lemgram Show word picture

Relaterade ord (SWE-FN)
ord, term, fackterm
glosa...

KWIC Statistics Word picture

Results: 88,127

Previous 1 2 3 4 5 6 7 8 9 10 11 .. 3525 3526 Next

Show context

ASPAC SVENSKA (does not support extended context)

(Den här gången var hon glad att ingen kunde höra henne, för **ordet** lät inte riktigt rätt.I fall på sig och började läsa, men hennes huvud var så fullt av hummerkadriljen att hon knappt visste vad hon sade, och **orden** blev verkligen ganska konstiga:
Jag har glömt **order**.Jag har hört vartenda **ord** ni sade.Låt mig slippa höra det **ordet** mer!Dessa **ord** följdes av en lång tystnad, endast avbruten av ett och
Hon urskilde **orden**: - Var är den andra stegen?



KWIC

Statistics

Word picture

Results: 88,127

Previous

1

2

3

4

5

6

7

8

9

10

11

..

3525

3526

Next Show context

ASPAC SVENSKA (does not

(Den här gången var hon glad att ingen kunde höra henne, för **ordet** lät int

a fall på sig och började läsa, men hennes huvud var så fullt av hummerkadriljen att hon knappt visste vad hon sade, och **orden** blev v

Jag har glömt **orden**.

Jag har hört vartenda **ord** ni sad

Låt mig slippa höra det **ordet** mer!

Dessa **ord** földe

Hon urskilde **orden**: - Var

Men rösten lät hes och besynnerlig, och **orden** var im

Det sista **ordet** kom r

Hon sade det sista **ordet** ett pa

Hon sade de sista **orden** högt,

" och den fanns absolut inte här förut ", sade Alice) och vid flaskhalsen satt fastbunden en papperslapp, och på den var **orden** " DRIC

(Alice hade ingen aning om vad latitud och longitud var för något, men hon tyckte det var roligt att säga långa, konstiga **ord** .

Jag begriper inte vad hälften av de där långa konstiga **orden** betyd

Sitt ned båda två, men säg inte ett **ord** förrän

Gripen svarade med nästan exakt samma **ord** som fö

stora, tårdränkta ögon men inte sade ett **ord** .

Den börjar med **orden** " När

En del **ord** var no


ckarn tjöt så att Alice knappt kunde höra **orden**:

iktigt, som om han velat ta reda på vilket **ord** som li

" för kålmasken och det blev alldelens fel **ord** .

Dependency Tree

part-of-speech: pronoun



Corpus

ASPAC svenska

Text attributes

title: Alice i Underlandet

author: Lewis Carroll

language: swe

description: Översättning av Harry Lundin

Word attributes

part-of-speech: noun

baseform:

ord

lemgram:

ord (noun)

sense:

ord

final part: [empty]

initial part: [empty]

dependency relation: Direct object

msd: NN.NEU.PLU.DEF.NOM

Show Dependency Tree



KWIC

Statistics

Word picture

Graph


Line

Bar

Table

- ✓ flodvåg (substantiv)
- ✓ tsunami (substantiv)
- ✓ Σ

Trend diagram for words
tsunami versus *flodvåg* in newspaper articles, 2001-2013





Word picture for the noun *ord* (word):

Word's grammatical and collocational behavior
Based on MI, statistics from the selected corpora

ord (noun)

Search



Relaterade ord (SWE-FN)
ord, term, fackterm
glosa...

also as initial part final part and case-insensitive

KWIC: hits per page: 25 ▾ sort within corpora: not sorted ▾ Statistics: compile based on: lemgram ▾ Show word picture

KWIC

Statistics

Word picture

Show word class

Preposition	Pre-Modifier	ord	Post-Modifier	ord	Verb	Verb	ord
1. med	9191	ord	1. fri	2353	ord	1. betyda	358
2. utan	494	ord	2. ful	314	ord	2. återkomma	57
3. bakom	235	ord	3. vacker	376	ord	3. beskriva	58
4. mot	484	ord	4. hård	395	ord	4. använda	80
5. bortom	50	ord	5. tom	208	ord	5. som bäst beskriva	28
6. i brist på bättre	23	ord	6. ont	96	ord	6. i gp	62
7. mellan	125	ord	7. vänlig	120	ord	7. i ki-duks	20
8. ute efter	14	ord	8. engelsk	179	ord	8. av kärlek	30
9. trots	57	ord	9. fin	229	ord	9. för dag	41
10. om och om igen	6	ord	10. klok	100	ord	10. på guldvåg	20
11. me	6	ord	11. latinsk	59	ord	11. i mun	34
12. af	6	ord	12. fel	111	ord	12. kunna	111
13. för övrigt	9	ord	13. förflugen	37	ord	13. dyka upp	32
14. till sist	7	ord	14. ond	117	ord		
15. till intet förpliktigande	3	ord	15. grekisk	84	ord		
						1. stå	506
						2. betyda	242
						3. vara	2530
						4. använda	243
						5. väga	126
						6. väga ³	104
						7. väga tungt	62
						8. komma	540
						9. säga	258
						10. höra	106
						11. räcka ²	92
						12. räcka	92
						13. yttra	34
						14. uttala	42
						15. forsa	30
						1. använda	994
						2. skräda	256
						3. säga	1219
						4. sätta	585
						5. höra	456
						6. uttala	180
						7. yttra	141
						8. växla	175
						9. byta	273
						10. hitta	332
						11. väga ³	146
						12. väga	149
						13. få	804
						14. lära sig	140
						15. förstå	150



37 of 38 corpora selected — 354.58M of 356.10M tokens



Search history ▾

Extended

English ▾

26 languages paired with Swedish

baseform is

sun Aa

or

+

Add lang Search

KWIC: hits per page: 10 ▾ sort within corpora: not sorted ▾ Statistics: compile based on: word ▾

Parallel corpora view

KWIC Statistics

Results: 135

Previous 1 2 3 4 5 6 7 8 9 10 11 .. 13 14 Next Show context

er sat still just as she left her, leaning her head on her hand, watching the setting sun , and thinking of little Alice and all her wo
'kvar där hon hade lämnat henne . Hon satt med huvudet lutat mot handen och tittade på solnedgången och tänkte på lilla Alic
They very soon came upon a Gryphon, lying fast asleep in the sun .
De kom snart till en grip , som låg och sov i solskenet .
- timidly at first - to push a charming little sprig inoffensively upward toward the sun .

ASPAC SVENSKA-ENGELSKA (does not support extended context)

Corpus

ASPAC svenska-engelska

Text attributes

title: Alice in Wonderland (1865)
author: Carroll, Lewis
language: eng
description: [empty]

Word attributes



KWIC: hits per page: 10 ▾ sort within corpora: not sorted ▾ Statistics: compile based on: word ▾

KWIC

Statistics

Results: 135

Previous

1

2

3

4

5

6

7

8

9

10

11

..

13

14

Next

Show context

ter sat still just as she left her, leaning her head on her hand, watching the setting sun , and
t kvar där hon hade lämnat henne . Hon satt med huvudet lutat mot handen och tittade på

They very soon came upon a Gryphon, lying fast asleep in the sun

De kom snart till en grip , som låg ochsov i solskenet.

- timidly at first - to push a charming little sprig inoffensively upward toward the sun .

ett näpet och vänligt skott mot solen .

" I should like to see a sunset... Do me that kindness... Order the sun to s

- Jag skulle så gärna vilja se en solnedgång ... Var snäll och befall solen att

But if you tame me, it will be as if the sun cam

Om du tämjde mig skulle det lysa upp min tillva

Just so. Everybody knows that when it is noon in the United States the sun is se

Ja , sannerligen - när klockan är tolv i Amerika , går ju solen som alla vet ned i Fra

" And I was born at the same moment as the sun ... "

Och jag föddes just som solen ...

: hurt any more, he still had the delicious taste of cinnamon bun in his mouth, the sun was

längre , han hade fortfarande den härliga kanelbullesmaken kvar i mun , solen sken in gen

Corpus

ASPAC svenska-engelska

Text attributes

title: Alice in Wonderland (1865)

author: Carroll, Lewis

language: eng

description: [empty]

Word attributes

part-of-speech: NN

baseform: sun

**Parallel corpora
search results**

[Svenska](#) [English](#)

CORP Annotation Laboratory

Language of analysis:

English

Load example:

[Example](#)

- 1 Lexicography
- 2 Practical lex.
- 3 Theoretical le
- 4 syntagmatic a
- 5 developing th
- 6 the needs for
- 7 the data inco
- 8 'metalexicogr
- 9 focuses on th
- 10 provide a de
- 11 dictionary or
- 12 compilation,
- 13 (relatively r
- 14 e.g. legal le
- 15 and following
- 16 dictionaries.

- Bulgarian
- Dutch
- English
- Estonian
- Finnish
- French
- German
- Italian
- Latin
- Polish
- Portuguese
- Russian
- Slovak
- Spanish
- Swedish
- Swedish-dev

Positional attribute group

[word](#) [pos](#) [msd](#)[Show advanced settings](#)[Run!](#)

separate but equally important groups:
or craft of compiling, writing and editing dictionaries.
holarly discipline of analyzing and describing the semantic,
ionships within the lexicon (vocabulary) of a language,
components and structures linking the data in dictionaries,
in specific types of situations, and how users may best access
nd electronic dictionaries. This is sometimes referred to as
ed to lexicography is called a lexicographer. General lexicography
, use and evaluation of general dictionaries, i.e. dictionaries that
age in general use. Such a dictionary is usually called a general
uge for General Purpose). Specialized lexicography focuses on the design,
specialized dictionaries, i.e. dictionaries that are devoted to a
guistic and factual elements of one or more specialist subject fields,
ctionary is usually called a specialized dictionary or LSP dictionary
lized dictionaries are either multi-field, single-field or sub-field

<sentence id="en847b0-en80d1f"> [Show XML]

word	pos	msd	lemma
Lexicography	noun	NN	lexicography



KORP Annotation Laboratory

[Hide advanced settings](#)

[Run!](#)

Corpus name:

Root tag

Structural attributes



Tag:

[Show Makefile](#)

[Show JSON Settings](#)

[XML](#)


Show tags [Run!](#)

<sentence id="en847b0-en80d1f"> [Show XML]

word	pos	msd	lemma
Lexicography	noun	NN	lexicography
is	verb	VBZ	be
divided	verb	VBN	divide
into	preposition / subordinating conjunction	IN	into
two	numeral	Z	2
separate	adjective	JJ	separate
but	coordinating conjunction	CC	but
equally	adverb	RB	equally
important	adjective	JJ	important
groups	noun	NNS	group
:	punctuation	Fd	:
Practical	adjective	JJ	practical



KARP - Lexical infrastructure of SB



All resources (24) are **inter-linked** via Saldo, a Swedish association lexicon, that functions as a pivot for all lexicon resources.

Saldo contains around 130 000 entries, is organized by sense and each entry has a persistent identifier (PID).

Diapivot is a mapping between Saldo entries and entries (+ inflectional variants) in historical lexicons [SKOS principle; 20 names for *hens*; or “bakvade”-example]



KARP

Log in Download resources Cite Karp Svenska | English About Karp

24 lexical resources selected (all) — 720,246 lexical entries

Search history ▾

Simple

Extended

Editor 



tsunami (substantiv)

Search

through Diapivot



Hits per page: 25 ▾

 "kan idag verkligen inte fatta att det var så stort att få sitt första barn att man missar hela tsunami katastrofen"



Full Hits (3)



Saldo (1)

Sense Lemgram POS Primary Secondary Children (primary) Children (secondary)

tsunami 	tsunami (noun)	noun	floodvåg	förödande	tsunamikatastrof-	tsunamivarning 
	 (21399)					

Saldo morphology (1)

Lemgram POS Inherent Paradigm Morphology

tsunami (noun)	noun	u	nn_vu_safari	tsunami (nn_vu_safari) ...
 (21399)				

Lexin (1)



KARP

[Log in](#) [Download resources](#) [Cite Karp](#) [Svenska](#) | [English](#) [About Karp](#)



24 lexical resources selected (all) — 720,246 lexical entries

[Search history](#)

Simple

Extended

Editor 

Search for entries that match

Phonetic form

or

Wordform

Baseform

Msd

Phonetic form

Saldo Sense

Lemgram

Part of speech

Primary descriptor

Secondary descriptor

Grammar note

Text in definitions

Text in examples

Paradigm

Cefr

Form information

Raw frequency

Wpm

Source

Rank

equals





Sort by

Search

Hits p



Simple

Extended

Editor ↗

Search for entries that match



Phonetic form

equals

çö:k



or



Sort by Wordform

ascending

Search

Hits per page: 25

Full Hits (3)

Statistics

Lexin (3)

Baseform	Phonetic form	POS	Rank	Lexin-ID	Morphology	Gram
----------	---------------	-----	------	----------	------------	------

kök	çö:k	noun	1637	1078455	kök ...	
-----	------	------	------	---------	---------	--

[▶ translations](#)

rum där man lagar mat [Lexintema 10 11]

en lägenhet på två rum och kök

det kom härliga dofter från köket

köks|bord

Name dubbelimperativ

Illustration Fortsätt ställ frågor i frågestunden HÄR!

Berkeley ID

Type ▾ konstruktion
 direktiv huvudsats
+

Category S

FrameNet

Definition Konstruktionen omfattar [verb]v som inte kräver infinitivmärke i infinitivfras, i samordning.
Konstruktionen har vardaglig prägel. [Det inledande verbet]Modifierarverb har modifierande funktion.

Structure [V_{1,imp} V_{2,imp}]

Inheritance ▾ pseudosamordning
+

Keywords ▾ +

Common words ▾ fortsätta¹

sluta¹

+

Construction elements, internal ▾ name=Modifierarverb, cat=V, msd=imp, other=Modifierarverb

name=V, cat=V, msd=imp

+

Construction elements, external ▾ +

Examples ▾ [Fortsätt]Modifierarverb [sälj]v[dubbelimperativ] biljetter SJ – och sluta släng av barnen !

[Sluta]Modifierarverb [skriv]v[dubbelimperativ] så flummigt och redogör hur det verkligen ligger till , tack .

KARP – editing

Password protected
Goal: to edit all resources

LEMGRAM

fisk (noun)

 384421

Number of lemgram
occurrences in Korp



PART OF SPEECH

noun

INHERENT

u

PARADIGM

nn_2u_sten

BÖJNING

fisk ...

Statistics over form
usage in Korp




sg indef nom fisk: 215

sg indef gen fisks: 2

sg def nom fisken: 84

sg def gen fiskens: 3

pl indef nom fiskar: 79

pl indef gen fiskars: 0

pl def nom fiskarna: 45

pl def gen fiskarnas: 2

ci fisk-: 1 fisk: 215

cm fisk-: 1 fisk: 215

sms fisk-: 1

fisk² (noun) 294213

noun

u

nn_0u_månsing

fisk ...

som fisk i vatnet (multiword adverb)

 8

multiword adverb

abm_i_till_exempel

som fisk i vatnet (oböjl.)

som en fisk (multiword adverb)

 3348

multiword adverb

abm_i_till_exempel

som en fisk (oböjl.)

som en fisk på torra land (multiword adverb)

 135

multiword adverb

abm_i_till_exempel

som en fisk på torra land (oböjl.)



Log in



Svenska | Engelska About Karp

Q Karp

1 lexicons chosen ▾

Simple Search

Extended Search

Haus

Search

Hits per page:

25

Statistics...

⚙️

Sök på alla språk

svenska

engelska

tibetanska

danska

tyska

franska

finska

grekiska

hindi

italienska

kotgarhi

marathi

nepali

nederländska

portugisiska

spanska

ryska

telugu

jiddish

Search for items in
other languages



Q Karp

Log in



Svenska | Engelska

About Karp

24 lexicons chosen ▾

Simple Search

Extended Search

hus

Search

Hits per page: 25 ▾

Statistics...



Overview

Hits (725)

Language Comparison

svenska engelska tibetanska danska tyska franska finska grekiska hindi italienska kotgarhi

marathi nepali nederländska portugisiska spanska ryska telugu jiddish



SWE	ENG	DEU	FRA	FIN	HIN	ITA	NLD	POR	SPA	RUS
hus	the house, house	Haus	maison	talo	घर, ghar	casa	huis, huis	casa	casa	дом

[Log in](#)


Sver

[Q Karp](#)

24 lexicons chosen ▾

[Simple Search](#)[Extended Search](#)Find entries where or [+ or](#)[Add term](#)[Search](#)[Reset](#)Hits per page: [Statistics...](#)[Overview](#)[Hits \(65\)](#)[Language Comparison](#)[svenska](#) [engelska](#) [tibetanska](#) [danska](#) [tyska](#) [franska](#) [finska](#) [grekiska](#) [hindi](#) [italienska](#) [kotgarhi](#) [marathi](#) [nepali](#) [nederländska](#) [portugisiska](#) [spanska](#) [rykska](#) [telugu](#) [jiddish](#)

SWE	fyra	fem
ENG	four	five
BOD	bži	lna
DEU	vier	fünf
FIN	neljä	viisi
NEP	cāra	pāñca
RUS	четыре	пять





Korp & Karp in

- Corpus examples
- Swe FrameNet
- Saldo morphology
- Lexin
- Kelly
- Wikipedia
- Wiktionary



research - Advanced English

research

► **n**

1. systematic investigation to establish facts

Hypernyms: [investigation](#)

Hyponyms: [operations research](#), [field work](#), [marketing research](#), [microscopy](#), [probe](#), [scientific research](#)

2. **inquiry**, **enquiry** - a search for knowledge

"their pottery deserves more research than it has received"



SaldoM exercise: training inflection patterns



Language learners Train inflections, multiple-choice General purpose vocabulary 1 of 6 learner levels selected

Korp sentences

Fully automatic

self-study mode test mode timed test Generate

Result Tracker
Exercise name: Learners/Inflections, självstudier Correct/Total: 1/2

Train inflections, multiple-choice Choose an appropriate word form for the gap

Nr Sentence

2 Ännu en skatteförvaltning har slavat bort _____.

1 Husfasaderna pryds av enorma målningar med tecknade figurer som motiv.

Select a word: deklaration, deklarationen, deklarationens, deklarationer, deklarationerna, deklarationers

Select a word: målningar, målning

Correct answer: målningar

e.g. Saldo morphology

MÅLNING
lemgram: målning..nn.1;
part-of-speech: nn;
saldo-paradigm: nn_2u_mening;
inherent: u;

sg indef målning nom

sg indef målnings gen

sg def målningen nom

sg def målningens gen

pl indef målningar nom



KORP & KARP export

We are exporting our tools, if anyone is interested in using them for their corpora or lexica. They are free of charge, and we help with installation.



GÖTEBORGS
UNIVERSITET



Thank you!