

## Språkbanken och Korp: Mot en språkteknologibaserad forskningsinfrastruktur

Lars Borin  
Språkbanken/svenska språket, Göteborgs universitet  
Giellatekno, UiT

19/2 2014

## Språkbanken – vad, för vem, till vad?

vad är Språkbanken?

- ▶ en nationell resurs sedan 1975
- ▶ en FoU-enhet i språkteknologi (med nationella och internationella samarbeten, t.ex. EU-projekten [META-NORD](#) och [CLARIN](#))
- ▶ **fri tillgång till sökning i digitala, förädlade språkresurser (svenskt skriftspråk av alla gener från alla tider):**
  - ▶ textkorpusar (enspråkiga och parallella)
  - ▶ lexikonresurser (moderna och historiska)
- ▶ **unik kompetens inom området svenska språkresurser**

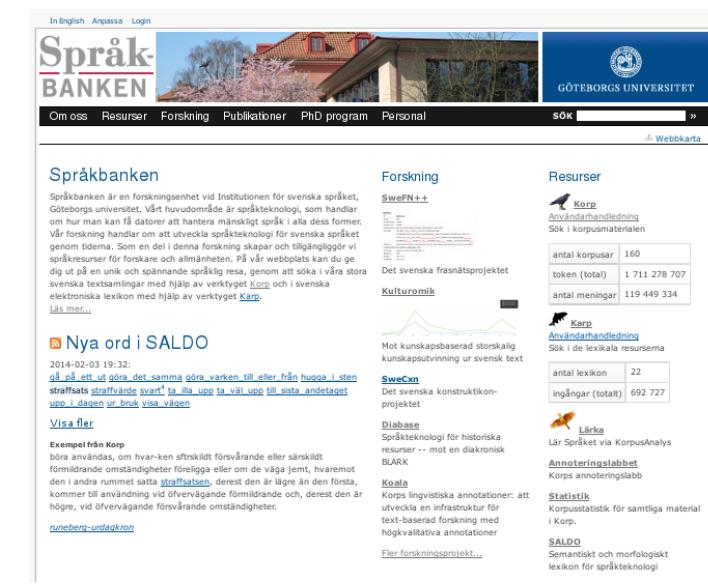
(traditionellt) för vem och till vad?

- ▶ språkforskare (nordister och lingvister)
- ▶ lexikografer
- ▶ språkteknologiforskare
- ▶ utbildning
- ▶ allmänheten

## Språkbanken: lite historia

- ~1970: första svenska korpusen: [Press-65](#)
- 1972: professor i språkvetenskaplig databehandling
- 1975: [Språkbanken \("Logoteket"\)](#)
- 1984: [datalingvistikprogrammet](#)
- 2000: [GSLT](#) (forskarskola i språkteknologi)
- 2004: pilotprojektet [Litteraturbanken](#)
- 2007: [CLT](#) (Centre for Language Technology)
- 2008: [språkteknologi](#) styrkeområde vid GU
- 2009: [strategiska GU-medel](#) till styrkeområdet språkteknologi
- 2011: svensk partner i [META-NORD](#)
- 2013: nationell samordnare för [SWE-CLARIN](#)

## Språkbanken: <http://spraakbanken.gu.se>



The screenshot shows the homepage of Språkbanken. At the top, there's a navigation bar with links for 'In English', 'Anpassa', 'Login', 'Språk-BANKEN' logo, and a search bar. Below the header, there's a main section titled 'Språkbanken' with a brief description and a link to 'Läs mer...'. To the right, there are several boxes for different research projects:

- Forsking**: SweFN++ (Mot kulturmärkning och språkpolitiken), Korp (Det svenska frasnätsprojektet).
- Resurser**: Korp (Antal korpusar: 160, token (total): 1 711 278 707, antal meningar: 119 449 334), Karp (Antal lexikon: 22, ingångar (totalt): 692 727), Lärka (Antal korpuser via KorpusAnalys).
- Nya ord i SALDO**: Mot kunskapsbaserad storskallig kunskapsutvärdering ur svenska text.
- SweCen**: Det svenska konstruktioniprojektet.
- Databas**: Språktechnologi för historiska resurser -- mot en diakronisk BLÄRK.
- Koala**: Kora språklogistiska annotationer: att utveckla en infrastruktur för text-baserad forskning med högkvalitativa annotationer.
- Statistik**: Korpusstatistik för samtliga material i Korp.
- SALDO**: Semantiskt och morfologiskt lexikon för språkteknologi.

## Ansikten utåt 1: Korp

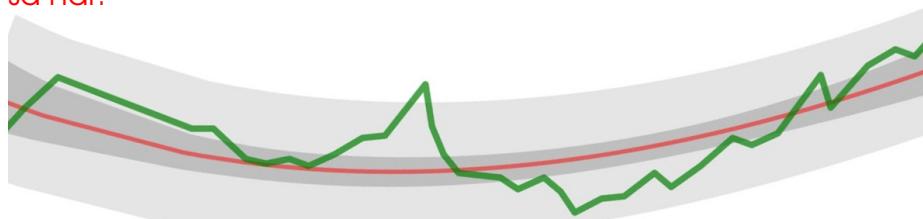
The screenshot shows the Korp search interface. At the top, there's a navigation bar with links like 'Moderna', 'Parallelta', 'Fornsvenska', 'Litteraturbanken', 'Spf 1800-1900', 'Äldre finlandssvenska', 'Faroiska', and 'Digidaily'. Below this is a search bar with the word 'förlust' and a count of '146 korpusar valda — 1 808 399 306 token'. The main area has tabs for 'Enkel', 'Utökad', and 'Avancerad'. A search result for 'förlust (substantiv)' is shown, with a snippet of text from the 'Åbo Underrättelser 2012' corpus: 'förlora tappa\_bort förlorande försäilla ge\_tillsämma mista tillspillo borttappa till\_spillo oförlorad slanya\_bort tillspilloge ge\_ill\_spillo'. Below this is a 'KWC' (Korpuswordcount) chart showing the frequency of 'förlust' across different pages (1-11). To the right, there's a 'Korpus' section with details: 'Åbo Underrättelser 2012', 'textattribut', 'datum: 2012-09-28', and 'ordattribut'.

## Korp-ideologin

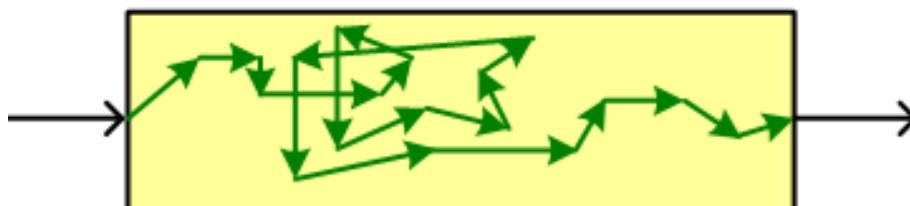
- ▶ Korp är Språkbankens korpusinfrastruktur
- ▶ Korp har en **teknisk sida** och en **användarsida**
- ▶ De tekniska lösningarna ska vara bra för användarna i stort och på lång sikt,
- ▶ vilket innebär en balangång
  - ▶ Att bygga solida tekniska lösningar som är generella tar ibland lång tid
  - ▶ medan en särlösning för ett individuellt fall kan åstadkommas relativt snabbt

## rörelsen framåt är viktig

så här:



men inte så här:



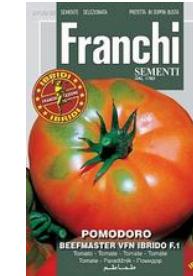
## tekniska lösningar

- ▶ Den viktigaste tekniska lösningen i Korp och dess syskon är
  - ▶ att korpusökmaskineriet är **strikt separerat** från de program som använder det, **inklusive själva sökgränssnittet**
- ▶ Vi talar om
  - ▶ Korp**s bakända** och
  - ▶ dess **framända**
- ▶ Det betyder att man kan ha ett godtyckligt antal gränssnitt för olika grupper och olika behov och
- ▶ "användaren" är typiskt inte en människa, utan ett datorprogram

## tekniska lösningar, 2

- ▶ Nästa viktiga tekniska lösning har att göra med "ingångarna" till bakändan
- ▶ Det gäller att hitta **rätt frihetsgrad/abstraktionsnivå**
- ▶ för då kan man blanda och ge på ett väldigt produktivt sätt
- ▶ Kanske man bäst tänker på bakändan som en samling funktioner som man kommer åt genom ett standardiserat gränssnitt.

## abstraktionsnivå/frihetsgrad



## tekniska lösningar, 3

- ▶ När man börjat tänka så
- ▶ blir det naturligt att göra så många funktioner som möjligt tillgängliga på samma sätt
- ▶ inte bara söksystemet, utan även korpusimport- och -annoteringsfunktionerna
- ▶ Man tänker förhoppningsvis mer i termer av modularisering och återanvändning
- ▶ **MEN** detta arbetsätt kräver en mycket hög och solid teknisk kompetens

## användarfunktioner

- ▶ Detta finns nu i Korp:
  - ▶ KWIC-visning
  - ▶ tidsuppmärkning och funktioner för att använda den
  - ▶ annotationer: ordklass/msd, lemgram, dependenssyntax(, ordbetydelse)
  - ▶ statistikfunktioner (tabell, tårtdiagram, trenddiagram)
  - ▶ ordbild
  - ▶ bortåt två miljarder ord moderna texter, och nästan en miljard ord äldre textmaterial (i Korplabbet)
  - ▶ nedladdningsbara "meningsmängder" (slumpvis omkastade texter)
  - ▶ möjlighet att lösenordsskydda korpusar och funktioner för användaradministration
  - ▶ all mjukvara (bakända och framända) fri och nedladdningsbar för egen installation

## Korp: korpusval

KORP

Enkel Utökad A

Sök efter [ ]

KWIC: träffar per sida: 25 ▾

146 korpusarvalda — 1 808 399 306 token

Markera alla  
3% Avmarkera

- ▶ Akademiska texter (2)
- ▶ August Strindberg (2)
- ▶ Finlandssvenska texter (52)
- ▶ Skyddade korpusar (0)
- ▶ Medicinska texter (12)
- ▶ Skönlitteratur (5)
- ▶ Sociala medier (21)
  - ▶ Blogmix (17)
  - ▶ Diskussionsforum (1)
  - ▶ Twitter (3)
- ▶ Tidningstexter (36)
- ▶ Tidskrifter (1)
  - ▶ Dramawebben (demo)
  - ▶ LäSBar! – Lättläst svenska och barnbokstext
- ▶ PAROLE
- ▶ Psalmboken (1937)
- ▶ SNP 78–79 (Riksdagens snabbprotokoll)
- ▶ SUC 2.0
- ▶ SUC 3.0
- ▶ SALT svenska-nederländska

## Korp: KWIC-visning

Sök efter [surfa (verb)] Sök även som □ förförd □ efterled och □ skiftfögesoberende

Relaterade ord surfa (verb)

bät tag buss scooter lifta bil urlåt vagn slade m-cilning skridska åka slängslalomkåka samiska cykel åltur kommunikationsmedel hess ståla skända spänningar passagerare hämtat ålmässing foton sluter rida räkstraka damma

Vissa fler

KWC: träffar per sida: 25 ▾ sortera inom

**Dependensrärd**

ordklass: verb

KWIC Statistik Ordbild

Antal träffar: 107

För regelns 1 2 3 4 5 Nasta Vissa fler

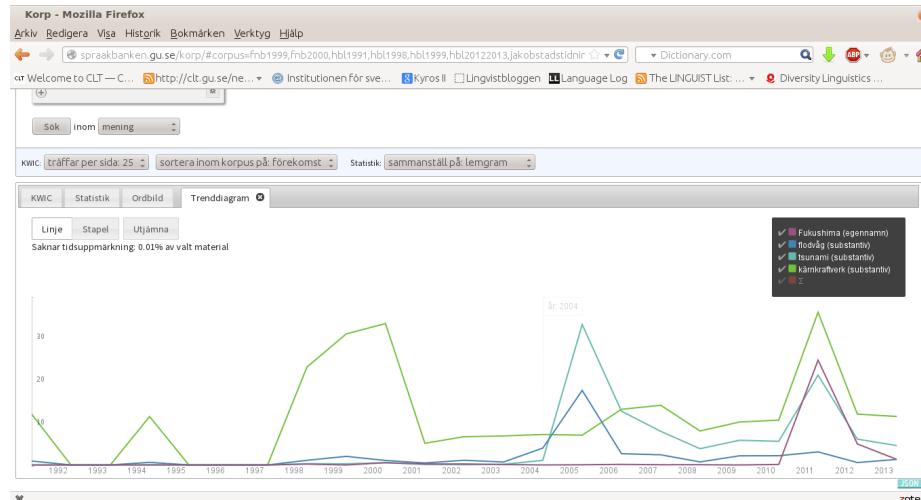
I januari 2008 uppmärksammades Creper då Computer Sweden avslöjade att kristdemokraterna i Mad till pornografiskaväbbplatser.

Bölsa nätverk som följer Wi-Fi-standarden IEEE 802.11n har nu överlämnats till svenska staten. Skurkarna kommer efter men trots det har tejenam tid att surfat. Dessa hittas sällan nogivits genom att surfat till det företag som man är intresserad av och titta efter filer och länkar relaterade till jobb, arbete, karriere och bankomat finns och för den som önskar att surfat på internet bliffl flygplatsen med fyra datorterminaler i avgångshallen samt trådlös anslutning till internt. Pardus GNU / Linux används för post-, surfat på internet, redigera foto, se på film och lyssna på musik. uppmärksammades Creper då Computer Sweden avslöjade att kristdemokraterna i Mad till pornografiskaväbbplatser.

Vim se Spindel är en spinndel som kan sova hela dagen för att han \* surfat på nätet hela natten. Kvartetten börja experimentera med olika musikstilar, bland annat punkrock, pop, surfat och skatemuus, blandat med humoristiska texter. På flygplatsen ges möjlighet att surfat trådlöst på internet med egen dator. Smith växte upp i Durban och startade surfat när han var sex år gammal. i bodde i strandstaden Berkleyvale, där Natalie blev känd som "surfabru" då hon surfat mycket i brist på annan aktivitet.

Korpus Svenska Wikipedia (november 2013) textattribut artikel/Gruheter url <http://sv.wikipedia.org/wiki/Gruheter> ordattribut ordklass: substantiv grundform: kristdemokrat leverantör: kristdemokrat (substantiv) betydelse: kristdemokrat förförd: [tom] utvärdering: [tom] dependensrärd: Subjekt (origt subjekt) medt karta till ordföraren Visa dependensrärd

## Korp: Trenddiagram



## Korp: Ordbild – surfa (verb)

Subjekt	surfa	Objekt	Adverbial
1. du	40 ▾	1. —	40598 ▾
2. treåring	24 ▾	2. porr	55 ▾
3. anställda	30 ▾	3. nät	32 ▾
4. svensk	33 ▾	4. våg	23 ▾
5. kund	25 ▾	5. 3g	18 ▾
6. proc <sup>2</sup>	21 ▾	6. stund	29 ▾
7. hälft	15 ▾	7. timme	37 ▾
8. användare	15 ▾	8. nätbutiker	8 ▾
9. besökare	14 ▾	9. sida	33 ▾
10. folk	31 ▾	10. hemsida	23 ▾
11. procent	22 ▾	11. internet	20 ▾
12. emanuelkarlsten	12 ▾	12. datavolym	6 ▾
13. mp3-bok	5 ▾	13. psl	6 ▾
14. man	26 ▾	14. skånelängor	6 ▾
15. våg	9 ▾	14. på blogg	43 ▾
		15. stund	48 ▾

# Korp: Ordbild – förlust (subst.)

Preposition	Attribut	förlust	Efterställt Attribut	Förlust	verb	Verb	förlust
1. efter	5699	1. rak	4057	1. på krona	5079	1. redovisa	2808
2. med	7544	2. stor	5345	2. på dollar	1060	2. bli	1442
3. trots	1363	3. tung	1324	3. föreskatt <sup>2</sup>	908	3. uppstå	505
4. utan	1641	4. ekonomisk <sup>2</sup>	1178	4. föreskatt	908	4. vara	4140
5. mot	797	5. ekonomisk	1178	5. efter finansnetto	658	5. svida	194
6. i och med	98	6. snöplig	289	6. på miljon	714	6. komma	1041
7. dagen efter	75	7. knapp	403	7. på euro	628	7. betyda	221
8. över	405	8. hedersam	199	8. på match	505	8. redovisa	159
9. vid	702	9. svår	503	9. för period	309	9. varan	171
10. på grund av	116	10. bitter	247	10. på miljard	323	10. beräkna	142
11. även om	34	11. enorm	272	11. förkvaratl	335	11. bero	160
12. förutom	68	12. klar	255	12. av mänskolin	129	12. landa	91
13. nära	66	13. smärtsam	132	13. av mångfald	147	13. landa <sup>2</sup>	91
14. till följd	24	14. eventuell	220	14. på mark <sup>2</sup>	204	14. göra	409
15. efter	6	15. ovantad	155	15. av arbetsstillfälle	110	15. kännas	158
		16. raka	10			15. visa	348
		17. raka	10				
		18. rak	10				
		19. sovjetisk	3				
		20. snöplig	1				

# Ansikten utåt 2: Korplabbet

Noderna | Parallelia | Fornsvenska | Litteraturbanken | Spf1800–1900 | Äldre finlandssvenska | Färöiska | Sibirienska | Klapplingsresor | Runebertidskrifter | Bibelstället | Lagrummet | Digidaily | Historisk

**KORP** 5 korpusar valda (alla) – 23 938 445 token

Enkel Utökad Avancerad

Sök efter rostratt (substantiv)  även som □ föref. □ efterled □ och □ skiftagesoberoende

Relaterade ord rostratt (substantiv) □ domkratt extrajudicell sprått rättsting inskrivning porträtt rättslagen krigsrätt förfoganderrätt dispositionerätt åsiktsrätt förhåndtagit rättlig besvarat rättsvis församling-frihet bekräftning rättsvalt självalt rättsvis statutslag processrätt yttranderätt boxningsrätt åtalrätt familierätt nödrätt överkörpat agitöreratt entomologeratt rättfändig

Vissa fler

KWC träffar per sida: 25 □ sorterat inom korpus på förekomst □ Statistik sammanställ på ord

**KWIC** **Statistik**

Antal träffar: 7 336

Föregående	1	2	3	4	5	6	7	8	9	10	11	...	298	299	Nästa	Visa kontext
------------	---	---	---	---	---	---	---	---	---	----	----	-----	-----	-----	-------	--------------

Diverse tideringar

textattribut

titel: Det nya Sverige  
datum: 1907

ordattribut

grundform:

I led narmast af skaligen enkla taktiska hänsyn, proklamerade de lösen: allmän **rostratt**. Utan allmän **rostratt**, ingen »nationell samlings» saga de rostratlosa likt självsvåldiga pojkar, som vilja mutas för att vara snåla. Man tanke bara på alla de fåfänga ord som talades om **rostratt** och samlung i det svenska »främesa hus» under rostrattdebatten anno 1906 – och man hoppas, att det är Hvilken är då för den den reella betydelsen af allmän **rostratt** – om man försöker se fullkomligt nyktert på saken? Men hvilken glädje får då industriarbetaren af den allmänna **rostratten**?

# Ansikten utåt 3: Korps annoteringslabb

**KORP** Annoteringslabbet

Ladda exempel: Drama Altstider Tabekten Labbar Exempelkorpus Språk: Svenska English

1 Att en fågel så kan svara, hör ju till det underbara!

Visa avancerade inställningar

VB: Verb

ord msd lemma lex saldo prefix suffix ref dephhead deprel

Att	SIN	att	att_sn.1	att_2		01	08	SS	
en	DT, UTR, SIN, IND	en	en.al.1	den..1, en..2		02	03	DT	
fågel	NN, UTR, SIN, IND, NOM	fågel	fågel_nn.1	fågel..1	få..av.1, få..vb.1	gel_nn.1	03	05	SS

# Ansikten utåt 4: Karp

Logga in Ladda ner resurser Referera till Karp Svenska | Engelska | Om Karp

**KARP** 23 lexikonsidor valda (alla) – 693 410 ingångar

Enkel Utökad Editor

hund (substantiv)  via diapivot

Träffar per sida: 25 □

Fullständiga träffar (41) **Statistik**

Föregående	1	2	Nästa
------------	---	---	-------

**Saldo** (2)

Betydelse Lemmat Ordförord Primär Sekundär Bam (primär) Bam (sekundär)

hund **hund** (substantiv) substantiv djur saltskap ● Karo - ● andegeon panna

• Pompe Karl XII ● apportera hamta

• bandhund binda ● bussa<sup>3</sup> anfalla

Visa alla (33) Visa alla (44)

**Dalins ordbok** 22 träffar

hund<sup>2</sup> **hund** (substantiv) substantiv usling

# Ansikten utåt 5: Lärka

Övningsgenerator | Hit-Ex (meningsläsbarhet) | Redigeringsverktyg för inlärarkorpusar | Svenska

**Lärka**  
LÄR språket via KorpusAnalys

Studenter i språkvetenskap Öva satsdelar 7 av 7 relationer valda

Helt automatisk

**Resultatändare** Övningstyp Korrekt/totalt  
Lingvister/SVHT1, självstudier 3/4

**Öva satsdelar** Valj en korrekt satsdel till den markerade frasen

4 Vattnet **tas** in och släpps ut i Öregundsgraven . Valj relation + Rätt svar  

3 Barnbidraget betalas **fr.o.m.** kvartalet efter det då barnet föddes . Valj relation + Rätt svar  

2 Farre barn skaffar man **sig** först då man ser en utväg ur sin fattigdom . Valj relation + Rätt svar  

TIPS →

# pågående projekt: SweFN++



Lars Borin, Dana Dannells, Markus Forsberg, Karin Friberg Heppin, Richard Johansson, Dimitrios Kolkkinakis, Leif-Jörn Olsson, Maria Toporowska Gronostaj, Jonatan Uppström, Kaarlo Voionmaa.

Följ utvecklingen via .

## Svenskt frasnät++ (SweFN++)

Detta projekt finansieras av VR/RFI 2011-2013 (dnr 2010-6013) samt med särskilda medel från Göteborgs universitet till styrelsenområdet språkteknologi (2009-2015).

SweFN++-projektet handlar om att släppta en central infrastrukturkomponent för svensk språkteknologi, nämligen en stor fritt tillgänglig lexikonresurs med rik lingvistisk information. Man kan säga att den planerade resursen kommer slå en bro mellan det förfutna och framtidens:

Det förfutna, därfor att vi vill återanvända en rad fria lexikonresurser som har tagits fram i olika projekt vid olika tidpunkter av olika forskargrupper, men som sen har fått mindre användning än de förtjänar främst på grund av idiosynkratiska format och brist på driftsmedel för att underhålla resurserna;

framtidens, därfor att vi till de integrerade befintliga resurserna vill lägga den typ av avancerad och mycket användbar semantisk och syntaktisk information om orden som man finner i det engelska Berkeley FrameNet (BNF) och några få liknande resurser för andra språk; ett arbete som vi planerar att göra i samarbete med den forskargruppen som står balon i BNF.

Eftersom dessa befintliga lexikonresurser representerar stora insatser i mōda och pengar och eftersom de i många fall innehåller högvärdig språklig information, vill vi alltså rädda så mycket som möjligt av dem från förgängelsen samt vidareutveckla dem.

Finansierat av VR/RFI

# SweFN++: SweFN

## Cure mod

domän	Med
kämelement	Affliction Body_part Healer Medication Patient Treatment
periferielement	Degree Duration Manner Motivation Place Purpose Time
exempel	<ul style="list-style-type: none"> <li>■ [Salvan]Medication [läker]u [skrubbsår]Affliction och [brännsår]Affliction</li> <li>■ [Affliction]</li> <li>■ [Läkaren]Healer [botade]u både [ryggskott]Affliction och [vatten i knät]Affliction , innan hon hamnade i svårigheter efter att ha utfört ett föryngringsexperiment med patienten.</li> <li>■ [Genterapi]Treatment [botade]u [dödsjuk i cancer]Patient</li> <li>■ [Läkaren]Healer [botar]u [kroppen]Body_part och [filosofen]Healer [botar]u [själen]Body_part , men det krävs ett engagemang för att lyckas.</li> <li>■ Traditionellt har [stafylokokinfektioner]Affliction enkelt [botats]u [med antibiotik]Medication .</li> <li>■ Syftet med terapi för en personlighetsstörning är inte att [fullständigt]Degree [botar]u [patienten]Patient , eftersom det varken är möjligt eller efterträvansvär.</li> <li>■ Han ansåg även att [Gud]Healer hade [helat]u [honom]Patient [från cancer]Affliction.</li> <li>■ [Transplantation]Treatment kan ha [botat]u [hiv-smittad]Patient ]Affliction .</li> </ul>
lus	vb <u>beta<sup>1</sup></u> <u>hele<sup>1</sup></u> <u>läka<sup>2</sup></u> nn <u>läkning<sup>1</sup></u> <u>botande<sup>1</sup></u> <u>helande<sup>1</sup></u> av <u>betiga<sup>1</sup></u>
kommentar	Ity ram jämfört med BFN. Den ursprungliga tolkningen av ramen Cure i BFN ges här en snävare tolkning som implicerar att ett positivt resultat av någon form av medicinskt behandling föreligger.
skapad av	MTG
skapad	2012-04-02
ändrad	2013-12-09

# digital areallingvistik

## Digital arealinguistics

### Word lists

Workshop October 2010

Workshop October 2011

Project Activities

## Word Lists

The languages are shown with their names and ISO 639-3 codes in parentheses. In case a language has no ISO 639-3 code, nothing is displayed.

### Languages

- Hindi (ISO 639-3 code: hin)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Marathi (ISO 639-3 code: mar)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Kannada (ISO 639-3 code: kan)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Telugu (ISO 639-3 code: tel)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Bengali (ISO 639-3 code: ben)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Punjabi (ISO 639-3 code: pan)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Khmer (ISO 639-3 code: kha)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Tamil (ISO 639-3 code: tam)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Nepali (ISO 639-3 code: nep)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Odia (ISO 639-3 code: ori)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Kannada (ISO 639-3 code: kan)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Naxi Kinnauri (no ISO 639-3 code)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Sanga (ISO 639-3 code: kfk)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Tigrinya (ISO 639-3 code: tig)  
LWT: [http://tab-1.lt](#)  
IDS: [http://tab-1.lt](#)
- Kharia (ISO 639-3 code: khr)

A (revised) Swedish IDS/LWT (ISO 639-3 code: swe) list is available for download in LMF format [here](#). It can also be searched online through [here](#).

### License



This work is licensed under a Creative Commons Attribution 3.0 Unported License.

Finansierat av VR. Ett samarbete mellan Språkbanken/Göteborg, lingvistik/Uppsala och lingvistik/MPI-EVA, Leipzig

# kunskapsbaserad kulturomik

## Culturomics

Culturomics: core NLP technologies

Culturomics: language over time

Culturomics: publications

Culturomics: question answering

Culturomics: text processing in historical texts

Culturomics: text processing in social media

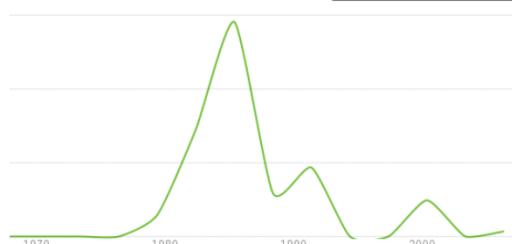
Culturomics: tracking semantic change

Culturomics: visualization

Culturomics: meetings

## Exploring language over time

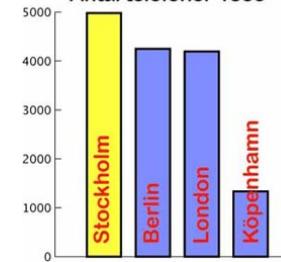
The following figures show the kind of results that emerge directly from a linguistically annotated text material available through Språkbanken's general corpus infrastructure. Unlike the culturomics work referred to earlier, the diagrams show the distribution of the lexemes (lexicon words) tsunami and flodväg in a newspaper material covering the years 2001–2011, including all inflectional forms and all compounds containing these words. This is made possible by the lexical analysis tools based on handcrafted resources used for annotating Språkbanken's corpora.



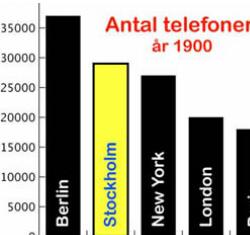
Finansierat inom VR:s ramprogram Det digitaliserade samhället – igår, idag, imorgon.  
Ett samarbete mellan Språkbanken/Göteborg, datavetenskap/Chalmers och  
datavetenskap/Lund.

# kulturomik: telefoner i Sverige

## Antal telefoner 1885



Linje Stapel Utjämna



Antal telefoner  
år 1900

## Antal telefoner per capita år 1900



✓ telegraf (substantiv)  
✓ telefon (substantiv)  
✓ Z

# nya projekt: Koala

## Infrastruktur

Korp

Karp

Lärka

SBLEX

FM-SBLEX

Koala

## Koala – Korps lingvistiska annotationer

Projektet Koala -- Korps lingvistiska annotationer -- handlar om att utveckla en infrastruktur för text-baserad forskning med högkvalitativa annotationer.

Korpusinfrastrukturen Korp på Språkbanken (<http://sprakban.en.gu.se>) innehåller stora mängder text av olika typ och ålder, som används av forskare inom olika områden och av allmänheten. Texterna innehåller lingvistisk uppmärkning, annoteringar, som ordklasser och syntaktiska roller, vilka hjälper till att filtrera sökresultaten för användaren. De läter oss hitta "sjöng" och "sjungit" när vi söker efter "sjunga" och alla ställen där Caesar är objekt till verbet besegrta utan att vi behöver titta på dem där han är subjekten, samt att vi inte behöver titta på meningar om lokaler när vi letar efter "lounge", utan kan fokusera på förekomsterna som handlar om djuret. Annoteringarnas kvalitet är avgörande för att få bra sökresultat, särskilt för forskare som annars kan behöva gå igenom tusentals irrelevanta meningar.

Målet för Koala-projektet är att förbättra annoteringarna, som har skapats automatiskt med välvända språktolkningssystem. Det görs genom att lägga till språklig kunskskap i systemet via de många resurser som finns tillgängliga via Språkbanken, samt genom att kombinera de olika annoteringsverktygen för lexikal analys, ordklasstagning, betydelsedisambiguering och syntaktisk analys till ett högkvalitativt system där annoteringar på ord- och meningsnivå informerar varandra och där systemet inte fattar beslut innan det har all tillgänglig information. De data och verktyg som blir resultatet kommer att göras fritt tillgängliga.

Projektet finansieras 2014-2016 av Riksbanks jubileumsfond.

Finansierat av RJ/infrastruktur

# nya projekt: MAPiR

Hem > Forskning > MAPiR

Webbkarta

## Forskning

Infrastruktur

SweFN++

META-NORD

KELLY

Kulturomik

CONPLISIT

Digital arealllingvistik

ITG

MOLTO

PINCORE

A System Architecture for ICALL

Akademiska ordistolar

Corpus-driven induction of linguistic knowledge

## MAPiR

Svenska språket under medeltiden, fornsvenska (ca 1225-1526), finns bevarat i manuskript, brev och tidigt tryck. Dessa dokument är värdefulla för många olika forskare, såsom lingvister intresserade av svenska språlets förändring under den tiden, juridiforskare som vill undersöka medeltida lagar, teologer som studerar tidiga översättningar av bibeltexter, eller medicin-historiker som är intresserade av medeltida folkläkekonst.

I MAPiR-projektet -- Metoder för automatisk Analys av Text i digitala Historiska Resurser -- skapar vi verktyg för automatisk lingvistisk analys av fornsvenska. Projektet är relaterat till Språkbankens satsning på historiska resurser, *Database*, och ligger inom forskningsområdet datalingvistik, vetenskapen om datamaskinell språkbehandling och datorstödd språkforskning. Genom att lägga till grammatiskt information i digitaliseringade fornsvenska texter underlättar vi studier av detta kulturarv och möjliggör nya sätt att undersöka det.

Att utveckla verktyg för fornsvenska är en utmanande forskningsuppgift, även med de främsta datalingvistiska metoderna. Detta beror på egenskaper i de fornsvenska texterna. För det första förändrades språket under den fornsvenska tiden vad gäller till exempel ordflöjd och ordböjning. För det andra finns ingen rätsättning i dagens bemärkelse. Samma ord kunde stavas på flera olika sätt. Ordet "mabir", som betyder man eller människa, stavades till exempel även "mæþr", "mændr" eller "meþer". Man kan till och med se olika stavningar för samma ord i ett enda stycke. För det tredje skiljer sig språket mycket åt mellan texterna. Det har gått 300 år mellan de äldsta och de yngsta texterna, och de kommer från olika geografiska områden och är av olika typ. För det fjärde kräver de flesta automatiska metoder antingen en mycket detaljerad datamaskinell beskrivning av ett språk, eller en större mängd text som redan har lingvistisk uppmärkning som datorn kan lära sig av. Inget av detta finns i dagsläget för fornsvenska. Kärnan i MAPiR-projektet är att utforska sätt att hantera dessa utmaningar i det fornsvenska materialet.

Finansierat av Marcus och Amalia Wallenbergs stiftelse

## nya projekt: distributionella metoder



### Forskningsprojekt

- ▶ Infrastruktur
- ▶ SweFN++
- ▶ META-NORD
- ▶ KELLY
- ▶ Kulturomil:
- ▶ CONPLISIT
- ▶ Digital areallingvistik
- ▶ ITG
- ▶ MOLTO
- ▶ PINCORE
- ▶ A System Architecture for ICALL
- ▶ Akademiska ordlistor
- ▶ Corpus-driven induction of linguistic knowledge

### Corpus-driven induction of linguistic knowledge

The project aims to find automatic, corpus-based methods for inducing linguistic constructions and semantic frames, and representing their meaning using distributional semantics. In addition, the project will study the interaction between the automatically induced meaning representations and symbolic, knowledge-based resources such as frame and construction inventories, and use the representations in natural language processing (NLP) tools. It will combine two recent developments in unsupervised NLP: distributional methods for building and processing geometric meaning representations from corpora, and unsupervised semantic frame and role induction.

The results of the project will advance research in NLP and have practical benefits in applications: Corpus-induced semantic representations will be able to move beyond single words, and be formalized in terms of frame semantics and construction linguistics. Automatic syntactic and semantic analysis tools can be made more robust since they can use linguistic information beyond the word level. Linguistic resource building will benefit by the automatic methods for construction and frame discovery that the project will devise. NLP applications such as information extraction, opinion mining, grammar checking, and computer-assisted language learning can integrate the semantic frames and linguistic constructions discovered by the project, and use their distributional representations to understand their meaning.

The project is funded by the Swedish Research Council, grant 2013-4944, *Distributional Methods to Represent the Meaning of Frames and Constructions*, and lasts between 2014 and 2018.

#### Staff:

- [Richard Johansson](#)

Finansierat av VR

## nya projekt: SWE-CLARIN



- ▶ CLARIN: ESFRI-förberedelsefas 2008-01 – 2011-06
- ▶ 9 svenska medlemmar (varav 2 partners)
- ▶ CLARIN ERIC startade 29/2 2012 med 9 medlemmar
- ▶ SWE-CLARIN-ansökan beviljad av VR 2013.
- ▶ Mål för SWE-CLARIN:

#### 1. bild en svensk nod i CLARIN ERIC:

- ▶ Göteborgs universitet (Språkbanken, SND)
- ▶ KTH (TMH)
- ▶ Linköpings universitet (NLP-lab)
- ▶ Lunds universitet (Humanistlaboratoriet)
- ▶ Stockholms universitet (datorlingvistik)
- ▶ Uppsala universitet (datorlingvistik)
- ▶ Språkrådet
- ▶ DigiSam

#### 2. bygga en basinfrastruktur för CLARIN i Sverige

## CLARIN-conceptet



- ▶ e-vetenskap – i form av språkteknologi som forskningsverktyg – för discipliner där **text** (och **tal**) är primärdata:
  - ▶ humaniora
  - ▶ samhällsvetenskap
  - ▶ (vissa sorters) medicin
- ▶ CLARINs betydelse växer i takt med digitaliseringen av kulturarvet och den elektroniska kommunikationens utbredning

## digital spetsforskningspotential



### Ökat intresse för gamla gruvor

Publicerat: måndag 02 juli 2007 kl 10:22, Nyheter P4 Norrbotten | Dela ▾



Prospektering.

Ny och effektivare teknik har gjort att intresset för gamla nedlagda gruvor har ökat markant. Lavergruvan inom Älvsvyns kommun är ett sådant exempel. Hos Bergstaten som handlägger prospekterings- och gruvfrågor ser man en stor anhopning av undersökningstillstånd i anslutning till gamla fyndigheter.

Precis som vid gruvbrytning, kräver stora mängder 'informationsglest' digitalt text- och talmaterial effektiv teknik för sökning, korrelering och korsindexering i det språkliga innehållet – även mellan språk – för att forskningen ska få ut användbara primärdata ur det.

Men bara som man kan fråga får man svar, så planerna för Språkbanken handlar om att kunna erbjuda nya sorters svar:

- ▶ korpusjämförelser
- ▶ namntaggning
- ▶ textmetadata
- ▶ syntaktisk sökning
- ▶ sökvisualisering (t.ex. trender, kartor)
- ▶ smartare träffgruppering, t.ex. visningssortering efter 'semantisk' kontext
- ▶ bättre syntaxanalys
- ▶ annotering av historiska material
- ▶ talspråk och ljud
- ▶ även annan forskning än språkvetenskap
- ▶ korpvarieteter (användningar och användare), men även andra gränssnitt (med gemensamma nattjänster i bakändan)

Vi också gärna veta vilka frågor forskare och andra vill kunna ställa till materialet.

tack!

