



UNIVERSITETET I BERGEN



Frå bandsalat til bandbreidd

Leksikografiske metodar i Revisjonsprosjektet
for Bokmålsordboka og Nynorskordboka

Gunn Inger Lyse
Revisjonsprosjektet for *Bokmålsordboka* og *Nynorskordboka*
<https://ordbok.uib.no>



UNIVERSITETET I BERGEN



Siteringsforslag: "Frå bandsalat til bandbreidd: leksikografiske metodar i Revisjonsprosjektet for Bokmålsordboka og Nynorskordboka" (2019).
Revisjonsprosjektet for Bokmålsordboka og Nynorskordboka. Universitetet i Bergen.
Presentasjon gjeve av Gunn Inger Lyse på faglunsj ved LLE, Universitetet i Bergen,
23.05.2019."
Kontakt: ordbokene@uib.no.
Denne presentasjonen er lisensiert under ein Creative Commons Namngjeving 4.0
Internasjonal Lisens.
URL til lisens: <http://creativecommons.org/licenses/by/4.0/>

I dette innlegget: presentere kildematerialet, verktøy og metoder som brukes og utvikles i det norske Revisjonsprosjektet for Bokmålsordboka og Nynorskordboka.
Seie litt om kva korpus vi brukar, kva søkjeverktøy vi har,
Gje døme på når korpus er til god hjelp – men óg døme på at korpus kan vere misvisande.



UNIVERSITETET I BERGEN



Revisjonsprosjektet for Bokmålsordboka og Nynorskordboka

- Hovedformål: oppdatere og forbetre Bokmålsordboka og Nynorskordboka (som Språkrådets viktigaste normeringsverktøy for bokmål og nynorsk).
- Tidsramme: 5½ år (oppstart haust 2018, prosjektslutt 2023)
 - Revidere eksisterande innhold;
 - Utjamne og samkøre omfang og lemmautval mellom ordbøkene.

23.05.19

SIDE 2



Utg.punkt er kort sagt:

I dette prosjektet skal leksikografene revidere to eksisterende ordbøker parallelt, én på bokmål og én på nynorsk.

(3 siste kulepunkt)

Revidere eksisterande innhold (tydingsinndeling, definisjonar, etymologi, uttale);

UNIVERSITETET I BERGEN

Ordboksarbeidet i Revisjonsprosjektet

Ein balansegong mellom å arbeide

Effektivt Etterretteleg

23.05.19 SIDE 3

Spørsmålet vårt: Hvordan kan leksikografene jobbe effektivt, etterrettelig og klokt (med et godt empirisk grunnlag) for å peke ut et modernisert og relevant ordtilfang i begge målformene?

Nokre døme:

UNIVERSITETET I BERGEN

Frå bandsalat...

b_ndsalat Begge Bokmål Nynorsk Avansert søk

Bokmålsordboka Nynorskordboka

Oppslagsord Ordbokartikkelen
bandsalat bändsalat m1; el. bandsalat m1
det at bänd (3) tyter ut slik at det er
umulig å få det på plass igjen

Vi har dessverre ingen informasjon om ordet 'b_ndsalat' i nynorskdatabase.
Vanlege feilkjelder:
• Skriftefel: Sjekk skrivemåten!
• Sok i feil ordbok: Bruk Begge-knappen!

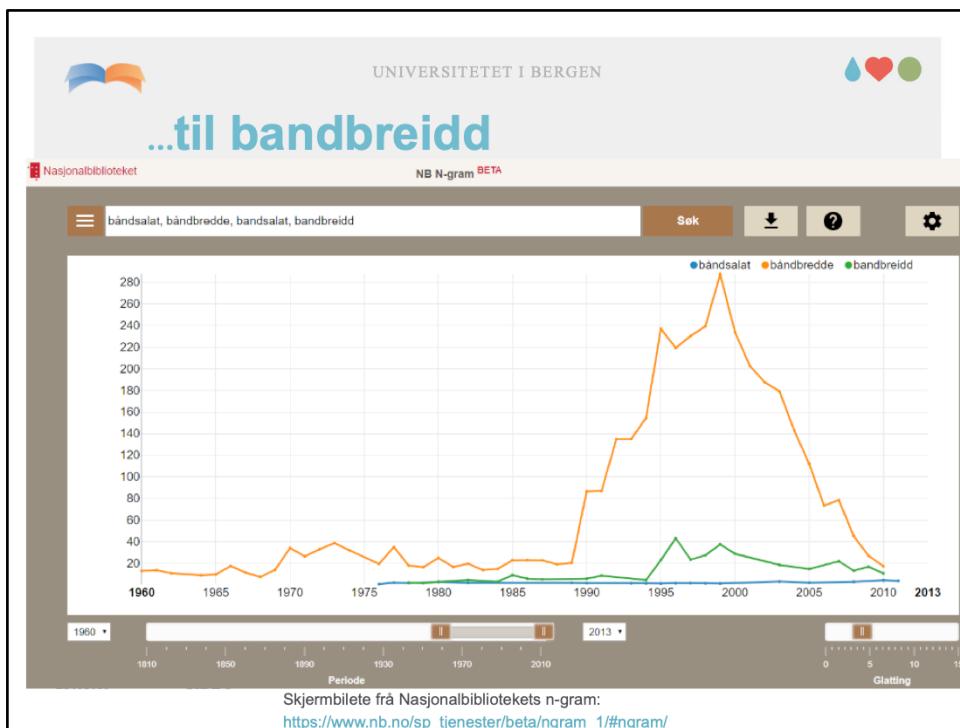
23.05.19 SIDE 4 FOTO: NTBScanpix



Bandsalat låg kun i BOB, men ikkje i NOB.

Bandsalat: som fenomen tona meir og meir ut då kassettspelaren vart erstatta av meir moderne måtar for å spele av musikk

Så er der til gjengjeld andre ord som fortener å kome inn, t.d. (klikk)



..bandbreidd.

Bandbreidd låg verken i BOB el NOB då prosjektet vårt starta opp.



UNIVERSITETET I BERGEN



Informasjonskjelder i Revisjonsprosjektet

- Språkrådet (normering)
- Språksamlingane ved UiB (usd.uib.no)
- tekstkorpus (lemmatifang, tyding, syntaktisk åtferd, døme på typisk bruk, frasar og fleirordsuttrykk som orda inngår i)
- introspeksjon
- andre ordbøker

23.05.19 SIDE 6



Den empiriske forankringa i **leksikografiarbeidet er viktig.**

Vi brukar dagleg det vi kallar "korpus":

-Tekstkorpus –kolleksjon av elektronisk tekst som er søkbar, og der du også kan analysere treffa.

Lemmatutval: peike ut eit sentralt ordforråd

Identifisere i kva tydingar eit ord vert brukt ("skiballett" som eiga tyding av "ballett")?

andenaud: vanskar med å dra anden (astma kan gje andenaud), men enda oftare: i overført tyding: mangel på naudsynte ressursar eller støtte (kommunen lir av økonomisk andenaud)

inf. om den syntaktiske "oppførsel"

Gode døme på typisk bruk av eit ord

Likevel nemne, for balansens skuld, at **ordbokarbeidet ikkje kviler åleine på å sjå på data.** (liste)

-Språkrådet (slår opp i normeringsvedtak - normerer bøyning, ordklasse, stavemåte).

-Vitskaplege språksamlingar (som Metaordboka) – for å sjekke det vi ikke finn belegg for i tekstkorpus, og/eller som allereie står i ordboka)

Anne: dlme på "corner" som har ei pokertyding som ikke er lett å finne i korpus;



Informasjon vi treng frå korpus

- Lemmautval:
 - ordfrekvens, over tid og på tvers av domene
bandsalat, ballongbukse, barnehageplass,..
 - frekvens på bøyingsformer (t.d. partisipp, passiv)
betinget, begeistret
det var toppen plass til fem personar
 - ordkollokasjonar (fleirordsuttrykk)
få auge på, antikvarisk verdi,
lett/kjapp/rask til beins
- Tyding: konkordansar
- Syntaktisk åtferd: konkordansar og kollokasjonar
- Gode bruksdøme: ordkollokasjonar
lovfestet rett til barnehageplass



Partisipp: INESS: lar oss lete spesifikt etter empirisk grunnlag for å se om et verb har kvaliteter som motiverer å legge dem inn som leksikaliserte adjektiver:

At de brukes ofte attributivt (en avansert pianist), om de samsvarsbøyes: de er avanserte



Relevante verktøy for å søkje i korpus

- CLARINO Bergen Center:
 - Corpuscle (verktøy for søk på ordnivå)
 - INESS (verktøy for søk i setningsanalysar)
- Nasjonalbiblioteket: NB n-gram og ordgalaksar
- Retriever: Atekst (avistekst)
- Universitetet i Oslo: HaBiT (norsk webkorpus), LIA



Prosjektet vårt har tilgang til forkjellig korpusmateriale, og her skal eg fokusere på dei to verktøya som er ramma inn øvst.

Dei svarar på to hovudbehov:

1. Vi treng å kunne søkje gjennom mykje tekst på ein enkel måte, mest mogleg fleksibel. => kombinere etteretteleg + effektiv
2. Vi lenar oss på mest mogleg kvalitetssikra materiale (meir orientert mot skriftspråk enn talespråk)

Leksikografene bruker verktøy for språkanalyse som er tilgjengelig gjennom språkinfrastrukturen CLARINO (<https://clarin.w.uib.no/>) og som er distribuert gjennom UiBs CLARINO Bergen Cent

Corpuscle er et verktøy for å søke på ord og fraser. Gjennom revisjonsprosjektet er Corpuscle utvidet til å søke i flere korpus samtidig (til sammen ca. 2,4 milliarder ord). Infrastrukturen INESS lar oss søke etter syntaktiske konstruksjoner som ikke er så lett søkbare i et tradisjonelt tekstkorpus.

treff	source	year	date
åmes Last har spunnet av gårde til den evige båndsalat. LAST JOURNEY: Kapteinens av or	VG	2015	2015-06-12
iar spunnet av gårde til den evige båndsalat. båndsalat . LAST JOURNEY: Kapteinens av orkestermuzi	VG	2015	2015-06-12
ssetten trenger oss, sier han og snurre opp båndsalaten . Men han innrommer at det er litt styr. Han	AP	2013	2013-07-21
et man aldri, det verste som kan skje er jo « båndsalat » og da er det tapt for alltid, forteller Hagen.	VG	2013	2013-02-16
» kjæreste May Irene Aasens mor. Frykter « båndsalat » DAT-taper, originale tegninger til Christo	VG	2013	2013-02-16
ieg som enkelt og greit. Her slipper man å få båndsalat på DV-tapen, det er enkelt å skifte disk og e	AP	2008	2008-01-07
å. Dessverre vil noen si, med minner om en båndsalat som deler den perfekte mikstapen som den	VG	2008	2008-02-23
enivist til minneses dal, der vi kan minne om båndsalat , susende lyd og kopiering av kassetter hjer	VG	2008	2008-02-23
» produksjonside - det høres gjerne ut som båndsalat og unormal avspillingshastighet flere steder.	DB	2007	2007-01-16
» var kassetten et overlegen musikkmedium	BT	2006	2006-03-31
» eller om videobåndet har nok igjen til å få i	DB	2002	2002-04-10
bånd Av RUNE SKOGSETH Ray Charles laget av NRK-kassetten som nesten stoppet den le	VG	1999	1999-07-17
ir over. I baksetet moret han seg med å lage båndsalat av videotapen, forteller Svein Åge Johansen	VG	1999	1999-07-17

Corpuscle:

Grensesnitt for å tilgjengeleggjere, søkje i og analysere tekstkorus. Verktøyet er utvikla av Paul Meurer, som no jobber ved Universitetsbiblioteket (UBB). Verktøyet inngår no i UBBs Clarino Centre Bergen.

FØRST NOKO OM KVA DU FINN DER

- I dette grensesnittet får du tilgang til ulike typar korpus: nokon ligg med open tilgang, men nokre tekstkorus har strengare tilgang grunna avtale med eigar av opphavsretten.
- både einspråklege og fleirspråklege korpus, på ulike språk.
- Der er korpus for ulike formål, med alt frå avistekst, Tekst skrivne av elevar, tli
- Transkriberte dialektopptak (prosjektet dialektendring)

Kva nyttar vi for revisjonsprosjektet? [klikk]



UNIVERSITETET I BERGEN



"Corpuscle-Lex" (eigen server)

Korpusnamn	Språk	Storleik (# ord)	Tidsrom	Sjanger	Lemma + ordklasse	Tilgang
Talk Of Norway	bokmål nynorsk	63,8 mill.	1999–2016	sakprosa	ja	open
Aviskorpus (bokmål)	bokmål	1509,1 mill.	1998–2015	sakprosa (avis)		open
NBs frie tekster (bokmål)	bokmål	516,4 mill.	1765–2013	blanda: sakprosa, skjønnlitteratur		open
Leksikografisk bokmålskorpus	bokmål	102,3 mill.	1985–2013	blanda: sakprosa, skjønnlitteratur	ja	avgrensa
Aviskorpus annotert	bokmål	29,0 mill.	2001–2009	sakprosa (avis)	ja	open
Forskning.no (2017)	bokmål	21,5 mill.	1998–2017	sakprosa (avis)	ja	avgrensa
Norsk Ordboks nynorskkorpus	nynorsk	107,8 mill.	1866–2012	blanda	ja	avgrensa
NBs frie tekstar (nynorsk)	nynorsk	46,2 mill.	1850–2010	blanda		open
Aviskorpus (nynorsk)	nynorsk	16,1 mill.	1998–2015	sakprosa (avis)		open

Vi har gjort eit utval som er lagd på ein dedikert server for leksikografane.

For eksempel kan vi gjøre komplekse søk i Nynorskkorpuset, Leksikografisk Bokmålskorpus og Nasjonalbibliotekets frie tekster samtidig.

UTVAL:

For prosjektet vårt er det viktig med:

- Stort materiale frå ulike domene, (jf. kolonna Sjanger & Storleik)
- som dekkjer eit breitt tidsaspekt (jf. kolonna Tidsrom)
- kvalitetssikra materiale (mest mogleg) – utval av korpus
- Språkleg analysert materiale (jf kolonna lemma + ordklasse)
- Fordeling bm-nn: ca 90%-10%
- Norwegian Nynorsk (nno): 170 mill. ord til saman
- Norwegian Bokmål (nob): 2,2 milliard
- TIL SAMAN: 2,4 milliard ord

(vi skal vise døme på at balansen i dette korpuset kanskje ikkje er optimalt - bias)

FUNKSJONALITET

På vår eigen server kan vi søkje i fleire korpus på ein gong.

Verdi: vi sparar enormt med tid.

Treffa kan vi deretter sortere ut frå attributt som kva kjelde treffa kom frå, eller kva tidsrom treffa er fordelt over.

UNIVERSITETET I BERGEN

Lemmatutval: trunkerte søk

"curl.*"

Søk Refine window: 5 tokens Stop | Lagrede søk ... | Lagre søker som feilles

Done. Running time: 0.04 sec. (0.05 CPU sec.)

Treff 1 – 30 av 6693 | Forrige Neste | Gå til: [] | Last ned (Excel-modus) | Copy query URL | Vis linjefilter | Attributter ... | Linjer per side: []

Kontekststørrelse: 400px ;

corpus

avis-nnø	en mellom Voss og Medkilla i Prestegardsmoen i dag. Ballen	curla
avis-nnø	azeem Ahmed det meste sjølv då han skar inn frå hegje og	curla
avis-nnø	azeem Ahmed det meste sjølv då han skar inn frå hegje og	curla
avis-nnø	azeem Ahmed det meste sjølv då han skar inn frå hegje og	curla
avis-nnø	azeem Ahmed det meste sjølv då han skar inn frå hegje og	curla
avis-nnø	I sjå ut. TV2 har kjøpt OL-rettar. Atslå risikere vi i framtidia	curling
avis-nnø	istoria bak fotball, tennis, basketball, bordtennis, volleyball,	curling
avis-nnø	blideCredit> FOTO: ARNE S. GJONE ¶ Les også En skole for	curlingbarna
avis-nnø	Ir tåringane har det, går det ut på eitt. Nokre har kalla dei	curlingbarna
avis-nnø	Eirik Kval. Under mennesken i dag er ikkje kalla glasur-	curlinggenerasjon
avis-nnø	får dei unge mange kallenamn, som «lydig», «flinkis» og «	curlinggenerasjon
avis-nnø	274481.ece> < F ¶ ~ Norsk seier over Japan ¶ De norske	curlinggautta
avis-nnø	leikslasse, og at det på havets botn ligg ein tusen år gammal	curlingstein
avis-plain	ut i " på Hawaii, Paramount går snart i gang med " Girl in the	curl
avis-plain	ut i " på Hawaii, Paramount går snart i gang med " Girl in the	curl
avis-plain	mai 2003: ¶ Øvelse Sett repetisjonen ¶ Knebøy: 3 x 15 ¶ Leg	curl
avis-plain	ai og juni 1 ¶ Øvelse Sett repetisjonen ¶ Knebøy: 3 x 10 ¶ Leg	curl
avis-plain	smith 3-4 x 15 (på hver fot) ¶ Leg extension 3-4 x 15 ¶ Leg	curl
avis-plain	Smith 3-4 x 10 (på hver fot) ¶ Leg extension 3-4 x 10 ¶ Leg	curl
avis-plain	Nordby synes OL-isen er rask. - Det er ikke mye skru (*	curl
avis-plain	forbanna på isen og forholdene. Vi er et lag som liker mye	curl

treff

year
Inn i lengste hjørnet utan sjanse for målvakta. Fortuna vani
ballen i motsett hjørne. 0-2, og alt låg til rette for Heddø fo
ballen i motsett hjørne. 0-2, og alt låg til rette for Heddø fo
ballen i motsett hjørne. 0-2, og alt låg til rette for Heddø fo
med reklameavbrot. Samtidig har NRK vist at det finst alter
, golf og synkronsyning. Kvifor akkurat desse? Eg ville fort
- 06.02.2005 Svikt i lærebokene, ¶ svikt hos lærerne? - 04.
, barna som får kosta banen sin fri av foreldra. Dei lærer fo
for ingenting, men det er vaksne som har lagt opp til. ¶
Angrepa kjem gjerne når nokon går ut i media og taler fr
til Japan 8-5 i tordagsdagens første VM-kamp. ¶ NTB Publisert
- 8-8198;Nei, nei - han er ikke tusket - han er 500 år gai
" , og Warner Bros skal lage "Lisa Andersen story ", for å n
, og Warner Bros skal lage "Lisa Andersen story ", for å n
3 x 15 ¶ Leg extension 3 x 15 ¶ (ca. 30-60 sek. pause mellø
3 x 10 ¶ Leg extension 3 x 10 ¶ (ca. 30-60 sek. pause mellø
3-4 x 15 ¶ (ca. 30-60 sek. pause mellø hver serie) ¶ April,
3-4 x 10 ¶ (ca. 30-60 sek. pause mellø hver serie) ¶ Eftek
") i isen heller som hun hadde trodd. - Jeg må inntremme at
og dragninger, med mange steiner i spill. Det er dumt å sky

Kjelde for dette søket: Aviskorpus bm + nn i Copusclex

Enkelt trunkert søk på "curl."

Dette er et eit sørk vi ofte gjer for å sjekke om vi har fått med sentrale ord innanfor eit bokstavstrekk..

Søket vårt her:

Drøyt 6700 treff, der konkordansen gjev deg ordet i kontekst. Du kan velje ulike kolonner med informasjon knytta til kvart treff, t.d. kva år kjelda er frå (kolonna til høgre)

Framfor å sjå på konkordansane, kan ein også t.d. hente ut ordlister over kva ordformer som finst i treffa [klikk]



UNIVERSITETET I BERGEN

Lemmautval (forts.): ordlister

Documentation
Søk
Refine
window: 5 tokens
Stop
Lagrede søk ...

Antall treff: 6693, unique values: 429. Attributt: word | ignorer storskrivering | sorter: etter frekvens relative to: -

Side 1 av 2. [Previous] [Next]

1514 (22,62%) curling	21 (0,31%) curlingpresident	7 (0,10%) curling-	4 (0,06%) curling-sporten
913 (13,64%) curling-VM	20 (0,30%) curlinglandslag	7 (0,10%) curling-gull	4 (0,06%) curlingeksperten
439 (6,56%) curlinggutta	20 (0,30%) curlingspilleren	7 (0,10%) curlingbarn	4 (0,06%) curlingfest
301 (4,50%) curler	19 (0,28%) curlingguttene	7 (0,10%) curlingbarna	4 (0,06%) curlingforbund
204 (3,05%) curling-EM	18 (0,27%) curlingdamene	7 (0,10%) curlingdamer	4 (0,06%) curlinggenerasjon
159 (2,38%) curlingjentene	18 (0,27%) curlingsteiner	7 (0,10%) curlingforelder	4 (0,06%) curlinginnasats
150 (2,24%) curlinglaget	16 (0,24%) curlingforbundets	7 (0,10%) curlingkarrieren	4 (0,06%) curlingklubben
129 (1,93%) curlinglandslaget	16 (0,24%) curlingklovnenes	7 (0,10%) curlingkollegor	4 (0,06%) curlingkunster
121 (1,81%) curlinghallen	15 (0,22%) curling-gutta	7 (0,10%) curlinglagene	4 (0,06%) curlinglegenden
116 (1,73%) curlingherrene	15 (0,22%) curlingklubb	7 (0,10%) curlingsasjon	4 (0,06%) curlingmamma
113 (1,69%) curlinglag	14 (0,21%) curlingbuksene	6 (0,09%) curling-finalen	4 (0,06%) curlingmesterskap
112 (1,67%) curle	14 (0,21%) curlinggull	6 (0,09%) curlingdrønning	4 (0,06%) curlingnasjonen
111 (1,66%) curler	14 (0,21%) curlingkvinner	6 (0,09%) curlingfans	4 (0,06%) curlingproff
99 (1,48%) curlingmillioner	14 (0,21%) curlingmiljøet	6 (0,09%) curlingfeberen	4 (0,06%) curlingsenter
71 (1,06%) curlingforbundet	14 (0,21%) curlingeier	6 (0,09%) curlingfolket	4 (0,06%) curlingsjef
65 (0,97%) curlingbanen	13 (0,19%) curiere	6 (0,09%) curlinghistorie	4 (0,06%) curlingskipen
62 (0,93%) curlingguttas	12 (0,18%) curfa	6 (0,09%) curlinginteressen	4 (0,06%) curlingsport
60 (0,90%) curlingforeldre	12 (0,18%) curlingbukser	6 (0,09%) curlingjenter	4 (0,06%) curlingsportens
54 (0,81%) curling-seirer	12 (0,18%) curlingfeber	6 (0,09%) curlingkampene	4 (0,06%) curlingsten
54 (0,81%) curlingherrer	12 (0,18%) curlingforeldrene	6 (0,09%) curlingkonkurranse	3 (0,04%) curler
53 (0,79%) curlinghall	12 (0,18%) curlinglandslagets	6 (0,09%) curlingleksjon	3 (0,04%) curling-Norge
47 (0,70%) curlinbane	12 (0,18%) curinomenn	6 (0,09%) curles	3 (0,04%) curina-aale

(ved å klikke på «ordliste» til venstre i menyen får du ut Kva visar ei slik liste oss?)

1. Peikar ut gode kandidatar til oppslagsformer som bør vurderast med i ordboka, om dei ikkje allereie er med. (men seinare skal vi sjå døme på at høg frekvens ikkje fortel oss alt)
2. Slike lister viser noko om i kva grad eit ord er produktivt i samansetjingar. Kanskje er samansetjingane kandidatar til å kome med, og det fortel uansett noko om i kva grad grunnordet er sentralt i ordforrådet vårt.

UNIVERSITETET I BERGEN

Distribusjon (t.d. over tid)

CLARINO

Hjem
Komme i gang
Dokumentasjon
FAQ
Publikasjoner
Lenker

Korpusliste
Søk
Konkordans
Kollaksjoner
Distribusjon

Ordliste
Tekst
Metadata
Oversikt
Variabler
Korpsdok.
Lokalisering

23.05.19

Korpuskel :: Aviskorpus (Bokmål) :: Distribusjon

Avansert søk | bytt til Enkelt søker | Søkehistorie ...
"b.-ndbre, ?dd, ?, ?, ?"

Søk | Raffinér vindu: 5 tokens ▾ | Stop | Lagrede sok ... | Lagre søker som: felles
Done. Running time: 0.01 sec. (0.01 CPU sec.)

Vis distribusjon type: absolut ▾ | counts only ▾ | include structures ▾

	av word	relative to year	grupper etter word	og year	dato
<input type="checkbox"/> Ignore storskrivering, Δ: 0	<input type="checkbox"/> Ignore storskrivering, Δ: 1	<input type="checkbox"/> Ignore storskrivering, Δ: 2	<input type="checkbox"/> Ignore storskrivering, Δ: 3	<input type="checkbox"/> Ignore storskrivering, Δ: 4	<input type="checkbox"/> Ignore storskrivering, Δ: 5

Fractions sum up to 1.0 in each row. Fractions in blue are unweighted means of group fractions. Fractions in green are distributions of total numbers.

Side 1/1 av 1x1. | Last ned

(sum)	bandbrede	båndbrede	båndbredden	båndbredde	båndbredder
(sum)	756 (100,0)	1 (0,1)	521 (66,9)	214 (28,3)	1 (0,1)
	756 (100,0)	1 (0,1)	521 (67,5)	214 (29,7)	1 (0,5)
1998	5 (100,0)		3 (60,0)	2 (40,0)	
1999	24 (100,0)		12 (50,0)	11 (45,8)	1 (4,2)
2000	45 (100,0)		36 (80,0)	7 (15,6)	2 (4,4)
2001	74 (100,0)		59 (79,7)	15 (20,3)	
2002	19 (100,0)		14 (73,7)	5 (26,3)	
2003	21 (100,0)		17 (81,0)	4 (19,0)	
2004	11 (100,0)		6 (54,5)	4 (36,4)	1 (9,1)
2005	52 (100,0)	1 (1,9)	36 (69,2)	14 (26,9)	1 (1,9)
2006	73 (100,0)		38 (51,3)	21 (28,6)	2 (2,6)
2007	45 (100,0)		31 (68,9)	14 (31,1)	
2008	82 (100,0)		66 (80,5)	14 (17,1)	2 (2,4)
2009	53 (100,0)		35 (64,0)	18 (34,0)	
2010	47 (100,0)		29 (61,7)	17 (36,2)	1 (2,1)
2011	31 (100,0)		25 (80,6)	6 (19,4)	
2012	46 (100,0)		29 (63,0)	9 (19,6)	8 (17,4)
2013	71 (100,0)		49 (69,0)	20 (28,2)	2 (2,8)
2014	45 (100,0)		27 (60,0)	18 (40,0)	
2015	14 (100,0)		9 (64,3)	5 (35,7)	



Freq.	Delta	Collocate
74	-2	fjør _ hatten
1	2	« hatt» _ halitt
1	-2	deflasjonskrise _ Hattene
2	-2	høysåter _ Hattane
1	-1	SPARKA HATTEN
1	-1	DISSE HATTENE
48	-2	fjær _ hatten
4	-1	bredbremmete hatter
5	-1	bredbremmede hatter
2	-1	tresnutede hatter
2	-1	vidbremmede hatter
1	-2	HØY _ HATTEN
1	-1	trisnuta hattane
1	2	hattane _ utfrunsa
1	-2	stilethæl _ Hattane
7	-1	bredbremmete hatten
2	-1	SIN HATT

Kjelde for dette søket: LBK + nynorskkorpus i Copurscle-lex

Kollokasjoner er ord som har ein statistisk tendens til å bli funne saman. Corpuscle har eit knippe statistiske mål; fra veldig enkle (rein frekvens, relativ frekvens), til meir kompliserte statistiske mål.

Kollokasjoner er ofte til hjelp for å identifisere typiske bruksdøme i ordboka, men óg moglege underoppslag

Øvst: Fjør i hatten, nede på linje 7 fjær i hatten.

31 templatler lagra



Frekvens fortel ikkje alt

- Ein høg frekvens er ikkje åleine nok:
 - Korleis er ordet distribuert over tid?
 - Korleis er ordet distribuert på tvers av domene?
- Døme: søk på "aor.**" i Aviskorpuset (bokmål)



For å grunngje at eit ord er "sentralt" i vokabularet vårt, er det ikkje nok i seg sjølv med høg frekvens.

Distribusjon (over tid, ulike domene)

To døme[klikk]

The screenshot shows the CLARINO Corpuskel interface for the Aviskorpus (Bokmål) :: Ordliste. The search query "aor.*" has returned 113 unique values. The results are as follows:

Antall treff	Prosent	Treffer
58	(51,33%)	aortastenose
22	(19,47%)	aorta
8	(7,08%)	aortaklaffen
4	(3,54%)	aorta-ventiler
3	(2,65%)	aorta-disseksjon
2	(1,77%)	aortaklaff
2	(1,77%)	aortic
1	(0,88%)	aorakelsteiner
1	(0,88%)	aorhhh
1	(0,88%)	aarin
1	(0,88%)	aorta-aneurisme
1	(0,88%)	aorta-blodåren
1	(0,88%)	aortaaneurisme
1	(0,88%)	aortabuen
1	(0,88%)	aortaklaffene
1	(0,88%)	aortaklaffeprotese
1	(0,88%)	aortaklaffer

"aortastenose" ser kjempefrekvent ut! 58 treff, dobbelt så mange treff som "aorta" (som er i ordbøkene våre)

Men viss du ser på distribusjonen til "aortastenose" over tid (eller nøyare på kollokasjonerne)

[klikk]

The screenshot shows a web-based corpus tool interface. On the left, there's a sidebar with links like Dokumentasjon, FAQ, Publikasjoner, Lenker, Korpusliste, Søk, Konkordans, Kollokasjoner, Distribusjon (which is selected), Ordliste, Tekst, Metadata, Oversikt, and Variabler. At the top right, there are icons for Universitetet i Bergen, a heart, and a gear. Below the sidebar, there are search and filter options for 'Vis distribusjon' (type: absolutt, counts only, include structures), and dropdowns for 'av' (word, year, -), 'relative to' (year, -), 'grupper etter' (-), and 'og' (-). A note says 'Fractions sum up to 1.0 in each row. Fractions in blue are unweighted means of group fractions'. Below this is a table titled '(sum)' with a red oval highlighting the column header and the first row. The table has three columns: '(sum)', '58 (100,0)', and '58 (100,0)'. The first row is labeled 'aortastenose'. The second row is '2005' with values '58 (100,0)' and '58 (100,0)'. The third row is '2014' with values '1 (100,0)' and '1 (100,0)'. At the bottom left, it says '23.05.19' and 'SIDE 18'. The Universitetet i Bergen logo is at the bottom right.

(sum)	aortastenose	
(sum)	58 (100,0)	58 (100,0)
2005	58 (100,0)	58 (100,0)
2014	1 (100,0)	1 (100,0)

...så ser du at så å seie alle treffa er frå 2005, faktisk frå mars/april 2005, då kong Harald vart innlagd på sjukehus med hjerteklaffproblem (=aortastenose)

Eit liknande dømme er orda knytt til "askeskya" frå Island i 2010.

**Corpuscle-Lex :: Aviskorpus (Nynorsk), Aviskorpus (Bokmål),
Forskning.no (2017), Leksikalsk bokmålskorpus, NBs frie tekster
(Nynorsk), NBs frie tekster (Bokmål), Nynorsk-korpus, Talk Of Norway ::
Distribusjon**

Avansert søk | bytt til [Enkelt søk](#) [Query history ...](#)

"assistenttren[a|e]r"

Søk Refine window: 5 tokens | Stop | Lagrede søk
... | Lagre søker som felles

Done. Running time: 0.21 sec. (0.34 CPU sec.)

Vis distribusjon type: absolutt | counts only | include structures

av word: ignorerer storskriver, Δ: 0 filter:
 relative to corpus: ignorerer storskriver, Δ: 0 filter:
 grupper etter - ignorerer storskriver, Δ: 0 filter:
 og - ignorerer storskriver, Δ: 0 filter:

Fractions sum up to 1.0 in each row. Fractions in blue are unweighted means of group fractions. Fractions in green are distributions of total numbers.

Side 1/1 av 1×1. | [Last ned](#)

	(sum)	assistenttrenar	assistenttrener
(sum)	13264 (100,0)	163 (1,2)	13101 (98,8)
avis-nno	13264 (100,0)	163 (31,3)	13101 (68,1)
avis-plain	29 (100,0)	29 (100,0)	12977 (100,0)
fn-new	2 (100,0)		2 (100,0)
lbk	18 (100,0)		18 (100,0)
rnk	238 (100,0)	134 (56,3)	104 (43,7)

Assistenttrenar/-trener

Hvis et ord forekommer mange gonger kun i eitt kildedokument eller kun i aviskorpuset, så viser dette kun at ordet er frekvent i eit domene.



INESS og NorGramBank: søk og analyse (setningsnivå)

- **Trebank:** eit syntaktisk analysert tekstkorpus der kvar setning har ein detaljert syntaktisk analyse.
- **INESS:** ein infrastruktur for å bevare og gjere trebankar tilgjengelege (søk og analyse). Del av CLARINO Bergen Centre.
- **NorGramBank:** ein trebank for norsk, utvikla i prosjektet INESS (2010-2017).



Trebank: Eit syntaktisk analysert tekstkorpus der kvar setning er forsynt med ei detaljert syntaktisk analyse.

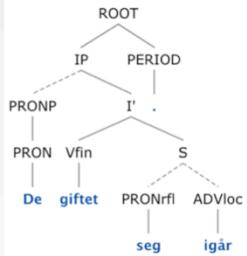
INESS:

NorGramBank: syntaktisk analyse med NorGram, ein komputasjonell grammatikk på bm og nn.

80 mill. ord (analysert tekst), eit subsett av det vi kan søkje på i corpuscle.

Fordelt på skjønnlitteratur, sakprosa og stortingstekst.

Bm-nn ratio: ca 90-10.

**C-structure****F-structure**

PRED	'gifte*seg<[8:de]>[4:seg]'
TNS-ASP	10 TENSE past, MOOD indicative
TOPIC	PRED 'de' NTYPE 9 NSYN pronoun REF +, PRON-TYPE pers, PRON-FORM de, PERS 3, NUM pl, DEF +, CASE nom
ADJUNCT	8 { PRED 'i går' ADV-TYPE temp }
OBJ	PRED 'seg' NTYPE 7 NSYN pronoun REF -, PRON-TYPE refl, PERS 3, NUM pl, CASE obl
SUBJ	[8] 0 VTYPE main, VFORM fin, STMT-TYPE decl





UNIVERSITETET I BERGEN



Søkjetemplat i INESS

Page 1 of 2 | Previous | Next | Go to page: Go | public private

Filter by name: | by description: | by template:

Click on a name to choose a template. (31 stored templates shown.) | Show template expansion

[Select marked templates](#) | [Store marked templates as sketch ...](#)

Name	Description
<input type="checkbox"/> * ADJ-coord(@ADJ)	Adjectives coordinated with an adjective
<input type="checkbox"/> * ADJ-degreeadvs(@ADJ)	Degree adverbs modifying an adjective
<input type="checkbox"/> * ADJ-modifies(@ADJ)	Nouns modified by an adjective
<input type="checkbox"/> * ADJ-modnominadj(@ADJ)	Adjectives modifying a nominal head adjective
<input type="checkbox"/> * ADJ-suff(@SUFF)	Adjectives derived with a suffix
<input type="checkbox"/> * ADV-degmodifies(@ADV)	Adjectives modified by a degree adverb
<input type="checkbox"/> * ADV-types(@ADV)	The types of an adverb
<input type="checkbox"/> * N-adjmod(@N)	The adjectives modifying a noun
<input type="checkbox"/> * N-defmascorfem(@N)	Feminine vs. masculine inflection of a noun

23.05.19 SIDE 22



31 templatler lagra


UNIVERSITETET I BERGEN
Signed in as Gunn Inger Lyse Samdal (gum).
blue heart green circle

inESS Sketch

Search in: nob-avis, nob-child, nob-fn, nob-lbk-av, nob-lbk-sa, nob-lbk-tv, nob-ndt-lfg, nob-novel, nob-novel_1, nob-novel_2, nob-novel_3, nob-novel_4, nob-novel_5, nob-novel_6, nob-novel_7, nob-sofie
 max #: | fragments: none only | fully disamb.: none only
 disambiguated: none only | unambiguous: none only

[Select query templates ...](#) |
 [Select sketch ...](#) |
 [Query history ...](#)

Template: * V-argframes(@V)

Description: Argument frames of a verb

Parameters:

@V:

23.05.19 SIDE 23



26 match types, 4081 matches. | Page 1 of 1 | Rows per page: | Download

Click on a row to see the matching sentences. | Copy format: plain BRO

UNIVERSITET I BERGEN

Count	#a: atom	#arg1: value	#arg2: value	#arg3: value
1545	gifte*seg	pronoun		
866	gifte*seg*med	pronoun	pronoun	
409	gifte*seg*med	pronoun	common	
346	gifte*seg*med	pronoun	proper	
201	gifte*seg	common		
128	gifte			
119	gifte*seg	proper		
96	gifte*seg*med	common	common	
63	gifte*seg*med	common	pronoun	
59	gifte*seg*med	proper	common	
54	gifte*seg*med	proper	proper	
52	gifte*seg*med	proper	pronoun	
26	gifte*seg*med	common	proper	
25	gifte*bort		pronoun	
20	gifte*bort	pronoun	pronoun	
18	gifte*bort		common	
15	gifte*seg*til	pronoun	common	
10	gifte*bort	pronoun	common	
8	gifte*bort	common	pronoun	
5	gifte*bort	common	common	
5	gifte*seg*til	pronoun	pronoun	
4	gifte*bort		proper	
3	gifte*seg*til	common	common	
2	gifte*bort	proper	pronoun	
1	gifte*bort	pronoun	proper	
1	gifte*seg*til	common	proper	

23.05.19 SIDE 24

UNIVERSITAS I BERGEN



<i>Count</i>	<i>#a: atom</i>	<i>#arg1: value</i>	<i>#arg2: value</i>	<i>#arg3: value</i>
1545	gifte*seg	pronoun	UNIVERSITETET I BERGEN	
866	gifte*seg*med	pronoun	pronoun	
409	gifte*seg*med	pronoun	common	
346	gifte*seg*med	pronoun	proper	
201	gifte*seg	common		

Page 1 of 11 [Previous](#) [Next](#) | Go to page: [Go](#) | [Download](#)

Click on a row to go to the sentence. Mouse over a row to see the structures.

<i>Treebank</i>	<i>Document</i>	<i>Trans.</i>	<i>Id</i>	<i>Sentence</i>	
nob-novel_7	oai:bibsys.no:biblio...	no	1739	En mann som vil gifte seg, er også i stand til slike handlinger, akkurat som sine forfedre.	Copy
nob-novel_7	oai:bibsys.no:biblio...	no	2135	– Saken er den at mor har tenkt å gifte seg!	Copy
nob-novel_7	oai:bibsys.no:biblio...	no	2194	Hun er en kvinne som gifter seg, akkurat som andre kvinner gifter seg hver dag, hver time på dagen!	Copy
nob-novel_7	oai:bibsys.no:biblio...	no	2416	Det var ikke noe galt i at en «kvinne» giftet seg igjen etter skilsmissen.	Copy
nob-novel_7	oai:bibsys.no:biblio...	no	2620	– Far giftet seg da han var på min alder.	Copy
nob-novel_7	oai:bibsys.no:biblio...	no	5153	Hvis du vil, skal jeg gi deg flere titalls eksempler på yngre sostre som har giftet seg før eldre, og det har ikke vært til hinder for at de eldste giftet seg med de beste ektemennene som tenkes kan.	Copy
nob-novel_7	oai:bibsys.no:biblio...	no	5892	Tanken på at datteren skulle gifte seg, gav ham en merkelig, ubehagelig følelse, enda det stred mot både fornuft og moral.	Copy

23.05.19 SIDE 25





UNIVERSITETET I BERGEN



Nytteverdi INESS

Særleg nyttig for

- funksjonsord (preposisjonar, adverb..)
- ord med mange syntaktiske samband (*gifte seg, falle i auga/få auge på/gjere store auge/ha auge for...*)
- ord med systematiske skilnader knytt til syntaktiske relasjoner
 - partisippformer og adjektiv

23.05.19 SIDE 26



Nå har Helge laget et søkeresultat ved navn * P-prepobjpred(@PREP). Dette returnerer en oversikt over alle objekter som står til ulike preposisjoner. Hvis jeg for eksempel søker på nedover, gir den tilbake toppresultatene kinn, rygg og gate (se skjermdump). Dette kan være nyttig for å finne de mest prototypiske eksemplene på bruk av ulike preposisjoner.

Det jeg vil er å se på en bestemt partisipp, f.eks. «anvendt», og jeg vil se på:

1. hvor mange ganger er den samsvarsbøyd som predikativ? (vs. hvor mange ganger er den ikke det)
2. hvor mange ganger står den i attributiv stilling (og hvor ofte ikke)

Jf. hypotesen du skisserte i en epost i etterkant av fredagsseminaret (som Margunn og Mikkel for øvrig roste! Jeg kunne dessverre ikke være med og høre)

En hypotese er da at høye verdier for (1) Kongruensbøyning og Attributiv bruk markerer gode kandidater for leksikaliserte adjektiver i ordboken: De har to sentrale adjektiviske egenskaper.
 ('de er avanserte', 'en avansert pianist')
 (kanskje ikke alltid samsvarsbøyning, men forekommer mest i attributiv stilling:
 'en etterlatt koffert', 'de ble etterlatt')



Oppsummering

Korpus er til god hjelp for leksikografen når det gjeld:

- lemmatilfang (ord inn og ord ut av ordboka);
 - underoppslag;
 - ordtydingar;
 - syntaktisk åtferd;
 - bruksdøme;
-
- ..Men korpus må brukast klokt, og kan ikkje erstatte leksikografiske vurderingar
 - Behov for vidareutvikling av tekniske løysingar







UNIVERSITETET I BERGEN

