

UiT

NOREGS  
ARKTISKE  
UNIVERSITET

# TROLLing – eit ope arkiv for språkdata

17. møte om norsk språk (Mons 17)

UiB og HVL, Solstrand, Os

22.-24. november 2017

Philipp Conzett

Universitetet i Tromsø – Noregs arktiske universitet  
(UiT)



# Disposition

---

1. Kva er TROLLing?
2. Arbeidsflyt og funksjonalitet i TROLLing
3. Kvifor skal forskarar arkivera dataa sine (i TROLLing)?
4. Samarbeid om språkdatahandtering

# Kva er TROLLing?

---

# Bakgrunn

---

- Idéen kom frå språkmiljøet på UiT. Behov for å kunna dela språkdata.
- Tok kontakt med UB UiT hausten 2013. UB hadde erfaring frå arbeid med open tilgang («open access») til forskingspublikasjonar.
- Arbeidsgruppe med språkvitarar, fagansvarlege for språkvitskap, rådgjevarar for open tilgang og IT-systemutviklarar.
- Rådgjevande gruppe med tre lingvistar frå Storbritannia og USA
- Lansering av TROLLing 18. juni 2014

**opendata.uit.no**



Foto: Kim G. Skytte

# Innhald: dokumenttypar

Ope arkiv for språkdata og statistisk kode som kan delast

- Rekneark med annoterte data
- Tabellar og figurar
- Lydfiler
- Videoopptak
- Statistisk kode
- ...

A	B	C	D	E	Bokmål	
1	word	first part	syntactic category of first part	second part	semantic category of second part	
2	adelsløve	adel	N	løve	animal	nei
3	anstalmaker	anstalt	N	maker	human	ja
4	apefant	ape	V (N?)	fant	human	nei
5	apegauk	ap/e	V (N?)	.	.	.
6	apekatt	ape	N	.	.	.
7	arbeidshest	arbeid	N	.	.	.
8	arbeidsjern	arbeid	N	.	.	.
9	arbeidsmaur	arbeid	N	.	.	.
10	armodskrek	armod	N	.	.	.
11	armodskryp	armod	N	.	.	.

Nesset, Tore, 2014, "Replication data for: Metafor og metonymi: personkarakteriserende sammensatte substantiv i norsk", [hdl:10037.1/10044](https://hdl.handle.net/10037.1/10044), DataverseNO, V1; negative word formation Norw database 4 CSV version.csv [fileName]

# Innhald: språk

---

- Slavisk: gamal austslavisk, gamal kyrkjeslavisk, mellomrussisk, olbansk/russisk, rumensk, russisk, tsjekkisk, ukrainsk
- Baltisk: latvisk
- Gresk: klassisk gresk
- Italisk: fransk, latin, rumensk
- Germansk: engelsk, islandsk, norsk, tidleg nyhøgtysk, tysk
- Andre: kinesisk, koreansk, nizaa, nordsamisk

# Innhald: fagdisiplinar og emne

---

- Fagdisiplinar:  
fonetikk, fonologi, morfologi, semantikk, syntaks
- Tilnærmingar:  
synkroni, diakroni, korpuslingvistikk, språktileigning
- Emne:  
argumentstruktur, aspekt, genustilordning, kasus,  
konstruksjonsgrammatikk, metafor, objektsplassering, ordlaging,  
tospråklegheit, trykk, vokalar, ...

# Statistikk per 18. november 2017

---

## Datasett:

Tal på datasett	60	I snitt per datasett:
Tal på datafiler	560	9
Tal på nedlastingar	3 503	58

# Statistikk per 18. november 2017

---

## Datasett:

Tal på datasett	60	I snitt per datasett:
Tal på datafiler	560	9
Tal på nedlastingar	3 503	58

## Forskarar (unike):

Totalt	55
Frå Noreg	28
Frå UiT	23
Frå utlandet	27

# Statistikk per 18. november 2017

## Datasett:

Tal på datasett	60	I snitt per datasett:
Tal på datafiler	560	9
Tal på nedlastingar	3 503	58

## Forskarar (unike):

Totalt	55
Frå Noreg	28
Frå UiT	23
Frå utlandet	27

## Institusjonar (unike):

Total	24
Frankrike	2
Kina	1
Latvia	2
Noreg	3
Russland	2
Storbritannia	3
Sør-Korea	2
Tsjekkia	1
Tyskland	4
USA	4

# Statistikk per 18. november 2017

## Datasett:

Tal på datasett	60	I snitt per datasett:
Tal på datafiler	560	9
Tal på nedlastingar	3 503	58

## Forskarar (unike):

Totalt	55
Frå Noreg	28
Frå UiT	23
Frå utlandet	27

## Ti-på-topp-datasett

<u>Nedlastingar</u>	<u>Språk</u>
329	Russisk
271	Russisk
215	Russisk
200	Russisk
200	Russisk
171	Norsk
148	Gamalkyrkjeslavisk
130	Gamalaustslavisk
123	Gamalkyrkjeslavisk
103	Spansk

## Institusjonar (unike):

Total	24
Frankrike	2
Kina	1
Latvia	2
Noreg	3
Russland	2
Storbritannia	3
Sør-Korea	2
Tsjekkia	1
Tyskland	4
USA	4

# **Arbeidsflyt og funksjonalitet i TROLLing**

---



# Tilrettelegging for gjenbruk

---

Tommelfingerregel: Ein fagfelle skal kunna gjenbruка datasettet også mange år etter at det er blitt publisert.

Følg retningslinene våre. I korte trekk:

- Bruk konsistente og forståelege filnamn.
- Lagre datasettet i arkivverdig/varig filformat i tillegg til originalformat.
- Beskriv datasettet i ei ReadMe-fil.

Meir info: <https://site.uit.no/trolling/getting-started/>

# Arkivering: obligatoriske metadata

<b>Title</b>	Genusvariasjon i norsk skriftspråk
<b>Author</b>	Conzett, Philipp (UiT The Arctic University of Norway) - ORCID: 0000-0002
<b>Contact</b>	 Use email button above to contact. Conzett, Philipp (UiT The Arctic University of Norway)
<b>Description</b>	Dette datasettet inneholder materialet ifrå ei undersøking av genusvariasjon i har sitt utspring i eit oppdrag eg fekk ifrå Språkrådet om å kartleggja i kva g genusnormeringa i bokmål og nynorsk er nytta i skriftlege kjelder. Datagrun undersøkinga, er beskrivne i prosjektrapporten (sjå "Related Publication" ne forklåra i ReadMe-fila. The data will be made openly available after the resu recognised scientific journal, but no later than January 1 2019. (2017-01-10)
<b>Subject</b>	Arts and Humanities
<b>Keyword</b>	Norwegian Bokmål Nynorsk grammatical gender variation corpus linguistics

# Arkivering: obligatoriske metadata

---

Title	Genusvariasjon i norsk skriftspråk
Author	Conzett, Philipp (UiT The Arctic University of Norway) - ORCID: 0000-0002
Contact	<p> Use email button above to contact.</p> <p>Conzett, Philipp (UiT The Arctic University of Norway)</p>
Description	Dette datasettet inneholder materialet ifrå ei undersøking av genusvariasjon i bokmål og nynorsk. Undersøkinga er beskrivne i prosjektrapporten (sjå "Related Publication" nede til venstre). The data will be made openly available after the results are published in a recognised scientific journal, but no later than January 1 2019. (2017-01-10)
Subject	Arts and Humanities
Keyword	Norwegian Bokmål Nynorsk grammatical gender variation corpus linguistics

# Arkivering: obligatoriske metadata

Title	Genusvariasjon i norsk skriftspråk
Author	Conzett, Philipp (UiT The Arctic University of Norway) - ORCID: 0000-0002
Contact	<p> Use email button above to contact.</p> <p>Conzett, Philipp (UiT The Arctic University of Norway)</p>
Description	Dette datasettet inneholder materialet ifrå ei undersøking av genusvariasjon i har sitt utspring i eit oppdrag og fekk ifrå Språkrådet om å kartleggja i kva g genusnormeringa i bokmål og nynorsk er nytta i skriftlege kjelder. Datagrun undersøkinga, er beskrivne i prosjektrapporten (sjå "Related Publication" ne forklåra i ReadMe-fila. The data will be made openly available after the resu recognised scientific journal, but no later than January 1 2019. (2017-01-10)
Subject	Arts and Humanities
Keyword	Norwegian Bokmål Nynorsk grammatical gender variation corpus linguistics

# Arkivering: obligatoriske metadata

Title	Genusvariasjon i norsk skriftspråk
Author	Conzett, Philipp (UiT The Arctic University of Norway) - ORCID: 0000-0002
Contact	 Use email button above to contact. Conzett, Philipp (UiT The Arctic University of Norway)
Description	Dette datasettet inneholder materialet ifrå ei undersøking av genusvariasjon i har sitt utspring i eit oppdrag eg fekk ifrå Språkrådet om å kartleggja i kva g genusnormeringa i bokmål og nynorsk er nytta i skriftlege kjelder. Datagrun undersøkinga, er beskrivne i prosjektrapporten (sjå "Related Publication" ne forklåra i ReadMe-fila. The data will be made openly available after the resu recognised scientific journal, but no later than January 1 2019. (2017-01-10)
Subject	Arts and Humanities
Keyword	Norwegian Bokmål Nynorsk grammatical gender variation corpus linguistics

# Arkivering: obligatoriske metadata

---

Title	Genusvariasjon i norsk skriftspråk
Author	Conzett, Philipp (UiT The Arctic University of Norway) - ORCID: 0000-0002
Contact	 Use email button above to contact. Conzett, Philipp (UiT The Arctic University of Norway)
Description	Dette datasettet inneholder materialet ifrå ei undersøking av genusvariasjon i har sitt utspring i eit oppdrag eg fekk ifrå Språkrådet om å kartleggja i kva g genusnormeringa i bokmål og nynorsk er nytta i skriftlege kjelder. Datagrun undersøkinga, er beskrivne i prosjektrapporten (sjå "Related Publication" ne forklåra i ReadMe-fila. The data will be made openly available after the resu recognised scientific journal, but no later than January 1 2019. (2017-01-10)
Subject	Arts and Humanities
Keyword	Norwegian Bokmål Nynorsk grammatical gender variation corpus linguistics

# Arkivering: obligatoriske metadata

Title	Genusvariasjon i norsk skriftspråk
Author	Conzett, Philipp (UiT The Arctic University of Norway) - ORCID: 0000-0002
Contact	 Use email button above to contact. Conzett, Philipp (UiT The Arctic University of Norway)
Description	Dette datasettet inneholder materialet ifrå ei undersøking av genusvariasjon i har sitt utspring i eit oppdrag eg fekk ifrå Språkrådet om å kartleggja i kva g genusnormeringa i bokmål og nynorsk er nytta i skriftlege kjelder. Datagrun undersøkinga, er beskrivne i prosjektrapporten (sjå "Related Publication" ne forklåra i ReadMe-fila. The data will be made openly available after the resu recognised scientific journal, but no later than January 1 2019. (2017-01-10)
Subject	Arts and Humanities
Keyword	Norwegian Bokmål Nynorsk grammatical gender variation corpus linguistics

# Arkivering: valfrie metadata

---

- Finansiør
- Relatert publikasjon
- Innsamlingsperiode
- Innsamlingsmetode
- Undersøkt tidsperiode
- Datakjelder
- Geografisk informasjon: Kva område dekkjer undersøkinga
- ...

# Filopplasting (+ ev. embargo)

---

- Mogleg å leggja embargo på filtilgang:

Dette datasettet inneheld materialet ifrå ei undersøking av genusvariasjon i norsk skriftspråk. Undersøkinga har sitt utspring i eit oppdrag eg fekk ifrå Språkrådet om å kartleggja i kva grad valfridomen i genussnormeringa i bokmål og nynorsk er nyttå i skriftlege kjelder. Datagrunnlaget og metoden som er nyttå i undersøkinga, er beskrivne i prosjektrapporten (sjå "Related Publication" nedanfor). Oppsettet på filene er forklåra i ReadMe-fila. The data will be made openly available after the results have been published in a recognised scientific journal, but no later than January 1 2019.



**Bokmalsmateriale\_m+n.ods**

# Lisensar: vilkår for gjenbruk

- Standardlisens i TROLLing: Creative Common / CC0  
= ingen restriksjonar på gjenbruk
- Men forventar kreditering gjennom tilvising

Files

Metadata

Terms

Versions

Terms of Use ▾

## Waiver

Our [Community Norms](#) as well as good scientific practices expect that proper credit is given via citation.  
Please use the data citation above, generated by the Dataverse.

CC0 - "Public Domain Dedication"



- Mogleg å bruka andre lisensar

# Kuratering

---

- Fagansvarleg på UB UiT sjekkar om datasettet er tilrettelagt for gjenbruk.

# Publisering: Referanse med varig URL

---

Holliday, Jeff; Turnbull, Rory; Eychenne, Julien, 2016, "K-SPAN (Korean Surface Phones and Neighborhoods)", [doi:10.18710/TWM79F](https://doi.org/10.18710/TWM79F) DataverseNO, V1,  
UNF:6:yYK7L4GaX1TTyBwMMhwZbg==

# Versjonering: V1 → V2

---

Holliday, Jeff; Turnbull, Rory; Eychenne, Julien, 2016, "K-SPAN (Korean Surface Phones and Neighborhoods)", doi:[10.18710/TWM79F](https://doi.org/10.18710/TWM79F), DataverseNO **V1**  
UNF:6:yYK7L4GaX1TTyBwMMhwZbg==



Holliday, Jeffrey J.; Turnbull, Rory; Eychenne, Julien, 2016, "K-SPAN (Korean Surface Phones and Neighborhoods)", doi:[10.18710/TWM79F](https://doi.org/10.18710/TWM79F), DataverseNO **V2**  
UNF:6:NWbRmiBvO5wWcDN2QHCQJw==

# Versjonskontroll

- Oversikt over endringar mellom versjonar:

Files    Metadata    Terms    Versions

 View Differences

	Dataset	Summary	Contributors	Published
<input type="checkbox"/>	2.0	<b>Files (Added: 3; Removed: 3);</b> <a href="#">View Details</a>	Julien Eychenne, Philipp Conzett	September 1, 2016
<input type="checkbox"/>	1.1	<b>Citation Metadata:</b> Author (3 Changed); <a href="#">View Details</a>	Julien Eychenne, Philipp Conzett	June 3, 2016
<input type="checkbox"/>	1.0	This is the first published version.	Julien Eychenne, Philipp Conzett	June 3, 2016

# Tilvising i publikasjonar: tidsskriftsartikkel

---

DE GRUYTER MOUTON

Folia Linguistica 2016; 50(2): 385–412

---

Fabian Barteld, Stefan Hartmann and Renata Szczepaniak\*

## The usage and spread of sentence-internal capitalization in Early New High German: A multifactorial approach

• • •

### Resources

The dataset and R script have been made available at the Tromsø Repository for Language and Linguistics (TroLLing): <http://dx.doi.org/10.18710/SJ4OQE>.

(<https://stefanhartmaneu.files.wordpress.com/2017/05/barteld-et-al-2016.pdf>)

# Tilvising i publikasjonar: ph.d.-avhandling

## In the beginning was the word

A study of monolingual  
and bilingual children's lexicons

Pernille Hansen



Center for Multilingualism in Society across the Lifespan  
Department of Linguistics and Scandinavian Studies  
Faculty of Humanities  
University of Oslo

Dissertation submitted for the degree of PhD  
December 2016

...

Hansen, P. (2016). Replication data for: What makes a word easy to acquire? The effects of word class, frequency, imageability and phonological neighbourhood density on lexical development. UiT Open Research Data Dataverse, V1. doi:10.18710/JEWIVW

(<http://www.hf.uio.no/multiling/personer/postdoktorer/perniha/dissertation-pernille-hansen-without-papers.pdf>)

# Gjenbruk: søk i TROLLing

---

**opendata.uit.no**



The Tromsø Repository of Language and Linguistics

DataverseNO > UiT Open Research Data > **TROLLing**

[Sign Up](#)

[Getting started with TROLLing](#)

Search this dataverse...

Find

[Advanced Search](#)

## Gjenbruk: søk i generelle søkeresultater: DataCite

---

<https://search.datacite.org/>



# Gjenbruk: søk i generelle søkeresurser: BASE

<https://www.base-search.net/>

The screenshot shows the BASE search engine interface. At the top, there is a navigation bar with links for 'Mobile' (orange), font size adjustment, and language selection ('En'). Below the navigation bar are five tabs: 'BASIC SEARCH' (highlighted in green), 'ADVANCED SEARCH', 'HELP', 'BROWSING', and 'SEARCH HISTORY'. A large search form is centered below these tabs. The search form has a green header bar labeled 'Your search'. It contains a search input field, a dropdown menu set to 'Entire Document', and a 'Find' button. To the left of the 'Find' button is a text overlay 'MORE THAN 5000 SOURCES!' in orange. Below the search input field are four search options with radio buttons: 'Boost open access documents' (selected), 'Verbatim search', 'Additional word forms' (selected), and 'Multilingual synonyms (Eurovoc Thesaurus)'. The background of the page features abstract blue and white geometric shapes.

# Gjenbruk: søk i generelle søkeruter: Oria

oria.no



Mitt bibliotek Alle bibliotek



Universitetsbiblioteket

oria.no

Universitetsbiblioteket Norske fagbibliotek

# Gjenbruk: søk i CLARINO

---

**<https://repo.clarino.uib.no/>**



The CLARINO Bergen Centre offers:

- A repository to search and deposit language data
- Online services for treebanks and other corpora
- Online editing of CMDI metadata



## Welcome to CLARINO Bergen Centre

CLARINO is a Norwegian infrastructure project jointly funded by the Research Council of Norway and a consortium of Norwegian universities and research institutions. Its goal is to implement the Norwegian part of CLARIN. The ultimate aim is to make existing and future language resources easily accessible for researchers and to bring eScience to humanities disciplines.



Search

[Advanced Search](#)

# Kvifor dela data (i TROLLing)?

---



# **Det kortet svaret: Fordi du (snart) må!**

---

# Krav frå finansiørar: EU

---

Frå 2017:



Horizon 2020  
European Union funding  
for Research & Innovation

«By extending the pilot, open access becomes the default setting for research data generated in Horizon 2020.»

«... as open as possible, as closed as necessary ...»

(Guidelines to the Rules on Open Access to Scientific Publications and Open Access to Research Data in Horizon 2020)

# Krav frå finansiørar: NFR

---

Frå 2017:



Forskningsrådet

«Forskningsrådets policy følger "åpen som standard"-prinsippet når det gjelder tilgang til forskningsdata.»

(Tilgjengeliggjøring av forskningsdata - Policy for Norges forskningsråd)

# Forventingar frå tidsskrift: *Language* (LSA)

---



LANGUAGE  
A JOURNAL OF THE LINGUISTIC  
SOCIETY OF AMERICA

«Where the data is not publicly available, (and there are often good reasons why it is not), authors should explain why it is not made available ...»

(Notes to Contributors to *Language*, published by the Linguistic Society of America)

# Krav frå tidsskrift: *Poljarnyj vestnik* (UiT)

---

*Poljarnyj vestnik*  
Norwegian Journal of Slavic Studies

«*Poljarnyj vestnik* acknowledges the need for Slavic linguists to archive their data in a safe place – and to share the data with their colleagues. Authors of articles for *Poljarnyj vestnik* are therefore requested to archive their data and code at TROLLing (the Tromsø Repository of Language and Linguistics).»

(Author Guidelines for *Poljarnyj vestnik*)

# Krav frå institusjonar: UiT

---



«Pkt. 4.4 Forskeren skal gjøre forskningsdata åpent tilgjengelig for videre bruk for alle relevante brukere, så fremt det ikke er juridiske, etiske, sikkerhetsmessige eller kommersielle grunner til ikke å gjøre det.»

(Prinsipper og retningslinjer for forvaltning av forskningsdata ved UiT. Vedtekte av Universitetsstyret 9. mars 2017. Gjeldande frå 1. september 2017.)

## **... og fleire vil følgja etter**

---

- Kunnskapsdepartementet kjem med nasjonal strategi for tilgjengeleggjering og deling av forskingsdata innan utgangen av 2017.
- Klare føringer for UH-sektoren

## **Det litt lengre svaret: Fordi forskinga tener på det!**

---

Tilgjengeleggjering og deling av forskingsdata bidreg til

- «Forbedret kvalitet i forskningen gjennom bedre mulighet til å bygge på tidligere arbeider og sammenstille data på nye måter»

(Tilgjengeliggjøring av forskningsdata - Policy for Norges forskningsråd)

## **Det litt lengre svaret: Fordi forskinga tener på det!**

---

Tilgjengeleggjering og deling av forskningsdata bidreg til

- «Forbedret kvalitet i forskningen gjennom bedre mulighet til å bygge på tidligere arbeider og sammenstille data på nye måter»
- «**Gjennomsiktighet i forskingsprosessen og bedre mulighet for etterprøvbarhet av vitenskapelige resultater**»

(Tilgjengeliggjøring av forskningsdata - Policy for Norges forskningsråd)

## Det litt lengre svaret: Fordi forskinga tener på det!

---

Tilgjengeleggjering og deling av forskningsdata bidreg til

- «Forbedret kvalitet i forskningen gjennom bedre mulighet til å bygge på tidligere arbeider og sammenstille data på nye måter»
- «Gjennomsiktighet i forskingsprosessen og bedre mulighet for etterprøvbarhet av vitenskapelige resultater»
- «**Økt samarbeid og mindre duplisering av forskningsarbeid**»

(Tilgjengeliggjøring av forskningsdata - Policy for Norges forskningsråd)

# Framleis ikkje overtydd?



[http://youtu.be/uEf0c0NT9\\_A](http://youtu.be/uEf0c0NT9_A)

TROLLing:  
Why linguists need it

Scotty      Robert Reynolds  
Professor    Laura A Janda  
TROLLing teller    Helene N Andreassen  
Voiceover    Peter Arne Svenonius

Screenplay    Laura A Janda  
Directing    Yngvar Natland

▶   ▶   🔍 4:19 / 4:44 Photo and sound Terje Bergli, Yngvar Natland

TROLLing - why linguists need it

sett 2 337 ganger

17   0   DEL   ...



UiT  
NORGES  
ARKTISKE  
UNIVERSITET  
Publisert 18. nov. 2014

ABONNER 512

# Samarbeid om språkdatahandtering: Kva?

---

- Kuratering: Korleis kan vi best mogleg leggja forskingsdata til rette for deling?

# Samarbeid om språkdatahandtering: Kva?

---

- Kuratering: Korleis kan vi best mogleg leggja forskingsdata til rette deling?
- **Metadata:** Korleis skal vi beskriva forskingsdata for at dei kan bli gjenfunne også på tvers av arkiv?

# Samarbeid om språkdatahandtering: Kva?

---

- Kuratering: Korleis kan vi best mogleg leggja forskingsdata til rette deling?
- Metadata: Korleis skal vi beskriva forskingsdata for at dei kan bli gjenfunne også på tvers av arkiv?
- **Tilvising: Korleis skal ein visa til forskingsdata i publikasjonar?**

# Samarbeid om språkdatahandtering: Kva?

---

- Kuratering: Korleis kan vi best mogleg leggja forskingsdata til rette deling?
- Metadata: Korleis skal vi beskriva forskingsdata for at dei kan bli gjenfunne også på tvers av arkiv?
- Tilvising: Korleis skal ein visa til forskingsdata publikasjonar?
- **Opplæring og informasjon:** Korleis kan vi nå ut til forskarane og andre aktørar?

# Samarbeid om språkdatahandtering: Kven?

---

- Arkivtenester og forskingsinfrastrukturnettverk:
  - CLARIN(O)
  - NSD
  - Språkbanken (Nasjonalbiblioteket)
  - TROLLing
  - ...
- Internasjonale organisasjonar og nettverk
  - Research Data Alliance: Interessegruppe for språkvitskap  
(«[Linguistics Data IG](#)»)
  - ...
- Språkrådet
- Forlag og tidsskrift
- **Forskarane**
- ...



Takk for merksemda!  
NB! Hugs TROLLing-plakaten!

[opendata.uit.no](http://opendata.uit.no)

# Referansar

---

Author Guidelines for *Poljarnyj vestnik*. Tilgjengeleg [her](#).

Guidelines to the Rules on Open Access to Scientific Publications and Open Access to Research Data in Horizon 2020. Tilgjengeleg [her](#).

Notes to Contributors to *Language*, published by the Linguistic Society of America. Tilgjengeleg [her](#).

Prinsipper og retningslinjer for forvaltning av forskningsdata ved UiT. Tilgjengeleg [her](#).

Tilgjengeliggjøring av forskningsdata - Policy for Norges forskningsråd. Tilgjengeleg [her](#).