



# CLARINO WP 7 TERMINOLOGY INTEGRATION

CLARINO Consortium meeting

Solstrand, Os, 13 September 2013

Gisle Andersen, Marita Kristiansen, Vemund Olstad



# Towards a national term portal

- In CLARINO, NHH wants to establish a national infrastructure to **harmonize** and **integrate** terminological language resources.
- It is not the aim to develop new terminologies per se, but to provide the technical **architecture** needed for their **integration and accessibility**, and to vouch for their **interoperability** with the CLARIN and ISO/TBX standards.
- Challenges:
  - variety of resources
  - variety of formats
  - many resources not updated



# Plethora of resources

Ressurs	Kortnavn	Institusjon	Kontaktperson	E-post	Ans.
Helsedirektoratets termbase	Hdir	Helsedirektoratet	Jim Yang	jim.yang@helsedir.no	GA
KB-N	KB-N	NHH	Marita Kristiansen	Marita.Kristiansen@nhh.no	MK
NHH Termbase	NHH	NHH	Marita Kristiansen	Marita.Kristiansen@nhh.no	MK
NHH Mikroøkonomen	NHH-M	NHH	Marita Kristiansen	Marita.Kristiansen@nhh.no	MK
NOT-basen	NOT	UiB/UNI R	Johan Myking/Klaus Johansen		GA
EØS-basen	EØS	Utenriksdepartementet	Cecilie Ovrum	cecilie.ovrum@mfa.no	GA
SNORRE	SNORRE	Standard Norge	Kjersti Drøsdal Vikøren	kdv@standard.no	GA
UHRs termbase	UHR	UHR	Rachel Glasser		MK
Rådet for Teknisk Terminologi	RTT	Fagbokforlaget (Uni)	Atle Eggereide	atle.eggereide@fagbokforlag	GA
Forskningsadministrativ terminologi	NFR	Norges forskningsråd	Else Lie		MK
Termar frå Språkrådets datatermgruppe	DataTerm	Språkrådet	Marianne Åsgård		GA
Norske oversettelser av termer fra Language Technology World	LTW	Uni Research	Tove Bjørneset	tove.bjorneset@uni.no	GA
Språkteknologisk terminologi	SprakTek	Uni Research	Tove Bjørneset	tove.bjorneset@uni.no	GA
Kystverket: Begreper	KV	Kystverket			MK
MeSH (Medical Subject Headings)	MeSH				MK
Risten.no		Universitetet i Tromsø	Sjur Moshagen		GA
GeoLeksi		Naturhistorisk museum	Inge Bryhni		
MetLex Meteorologileksikon		Meteorologisk institutt			
Statens kartverk		Statens kartverk			
Helsenett.no		Helsenett			
IKT og helse		Kompetansesenter for IKT i helse- og sosialsektoren			
Karateterminologi		Norges Kyokushin Karate-organisasjon			
Pasienthåndboken: Medisinsk ordbok		NHI			
Ship circular		Uni Research	Tove Bjørneset	tove.bjorneset@uni.no	
Adictionary and terminological analysis of merchant ship terms	MS	Marte Salberg	Marte Salberg		
Ordlista fra A-hinnsynskonferanse offishare		Norøredirektoratet, http://www.redori.no/nruobt/cmrs.nsf/doc/04732D08970			
Marok-øngolkkordlister for fyrkarar av Einar Aarlid (1971) Oslo: Bjarne H. Reenekauq					
Bokrivelte av relevante fyrkeredkap og fyrkeraktivitet i Norgos økenom	Olijedirektoratet				
Grønn ordbok	UMB				
Commin	UMB?				



# Terminologi.no

- <http://www.terminologi.no/>

The screenshot shows the homepage of Terminologi.no. At the top left is the NHH logo. At the top right are links for CLARINO, NHH, and Kontakt. Below the header is the main title "Termportalen" with its logo. A navigation bar below the title includes links for Forsiden (highlighted in white), Søkeside, Om Termportalen, Termbasene, Om CLARINO, Publikasjoner, and language links (Norwegian and English). The main content area starts with the text "Du er her: Forsiden".

## Termportalen ved NHH

Velkommen til Terminologi.no – en nasjonal portal for terminologi!

I Norge har det i lang tid vært etterlyst et initiativ for å etablere en nasjonal termportal. Dette arbeidet er nå i gang i regi av CLARINO, et nasjonalt prosjekt for forskningsinfrastruktur finansiert av Norges Forskningsråd (NFR).

Termportalen vil gi brukere fri tilgang til norsk terminologi innenfor en lang rekke fagområder, og gjøre det mulig å søke på tvers av termbaser og fagområder.

Termportalen er under utvikling og er i ferd med å fylles med innhold. Arbeidet med Termportalen er organisatorisk tilknyttet Institutt for fagspråk og interkulturell kommunikasjon, Norges Handelshøyskole (NHH), og er et samarbeid mellom NHH, Universitetet i Oslo og Universitetet i Bergen.



# Arbeidet frem til nå

- Innhenting av data
  - 8 baser konvertert
  - Nærmer oss avlevering på flere andre
- Vurdering av innhold / modellering
  - Ulike eksportformat
  - Ulik struktur på basene (alt fra enkle tabeller til komplekse baser)
  - Veldig varierende innhold
- Konverteringsrutiner
  - Skript / stilark for hver enkelt base
  - Alt konverteres til ett standardformat (TBX)
- Testversjon av Termportalen
  - Enkel prototype lansert



# Oppgaver for høsten 2013

- Databaseoppsett

- Modellering av relasjonell base
  - Oracle eller Postgres

- Eksportformat

- Oppdatering av TBX
  - Basert på erfaringer fra første runde med konverteringer
- Baser med ferdigstatus klar for avlevering til CLARIN
  - Koordineres m. UBB

- Redigeringsapplikasjon

- Testversjon klar i løpet av høsten
  - ‘Bare-bones’-versjon med enkelt design
  - Kan forhåpentligvis testes i undervisning

- Termportalen

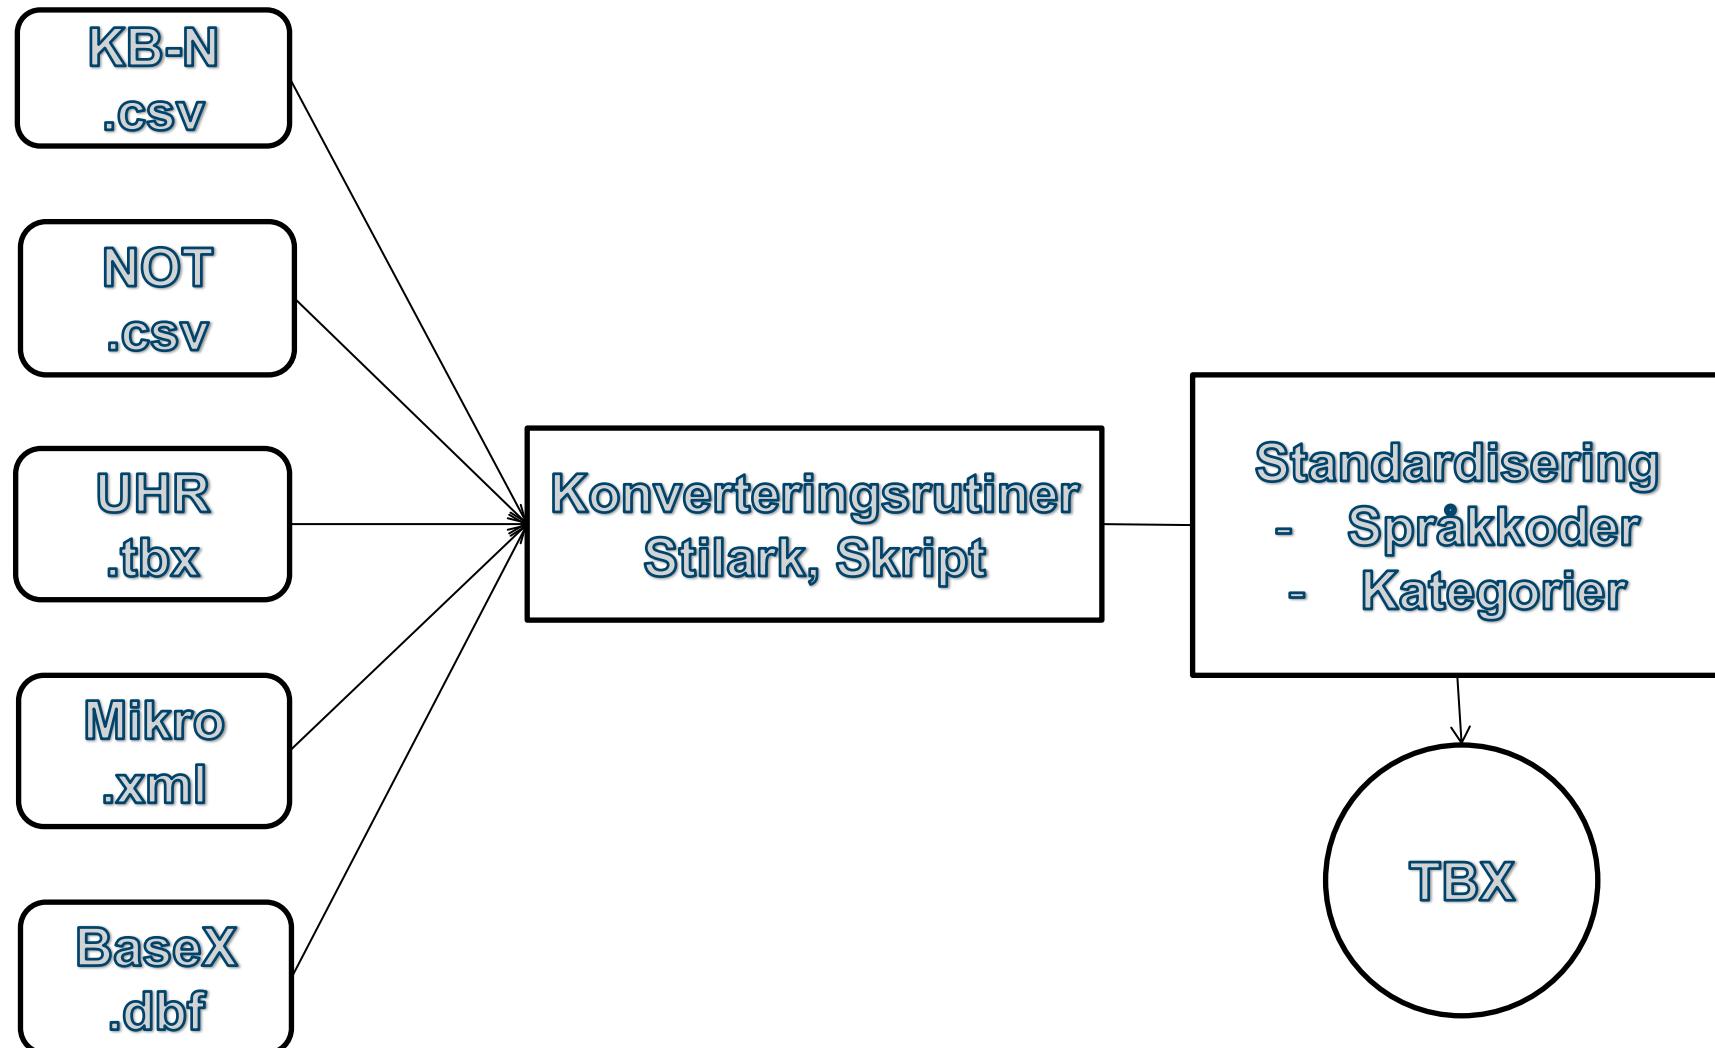
- Utvide søkefunksjonalitet iht. prosjektbeskrivelse



# Status – terminologiske ressurser

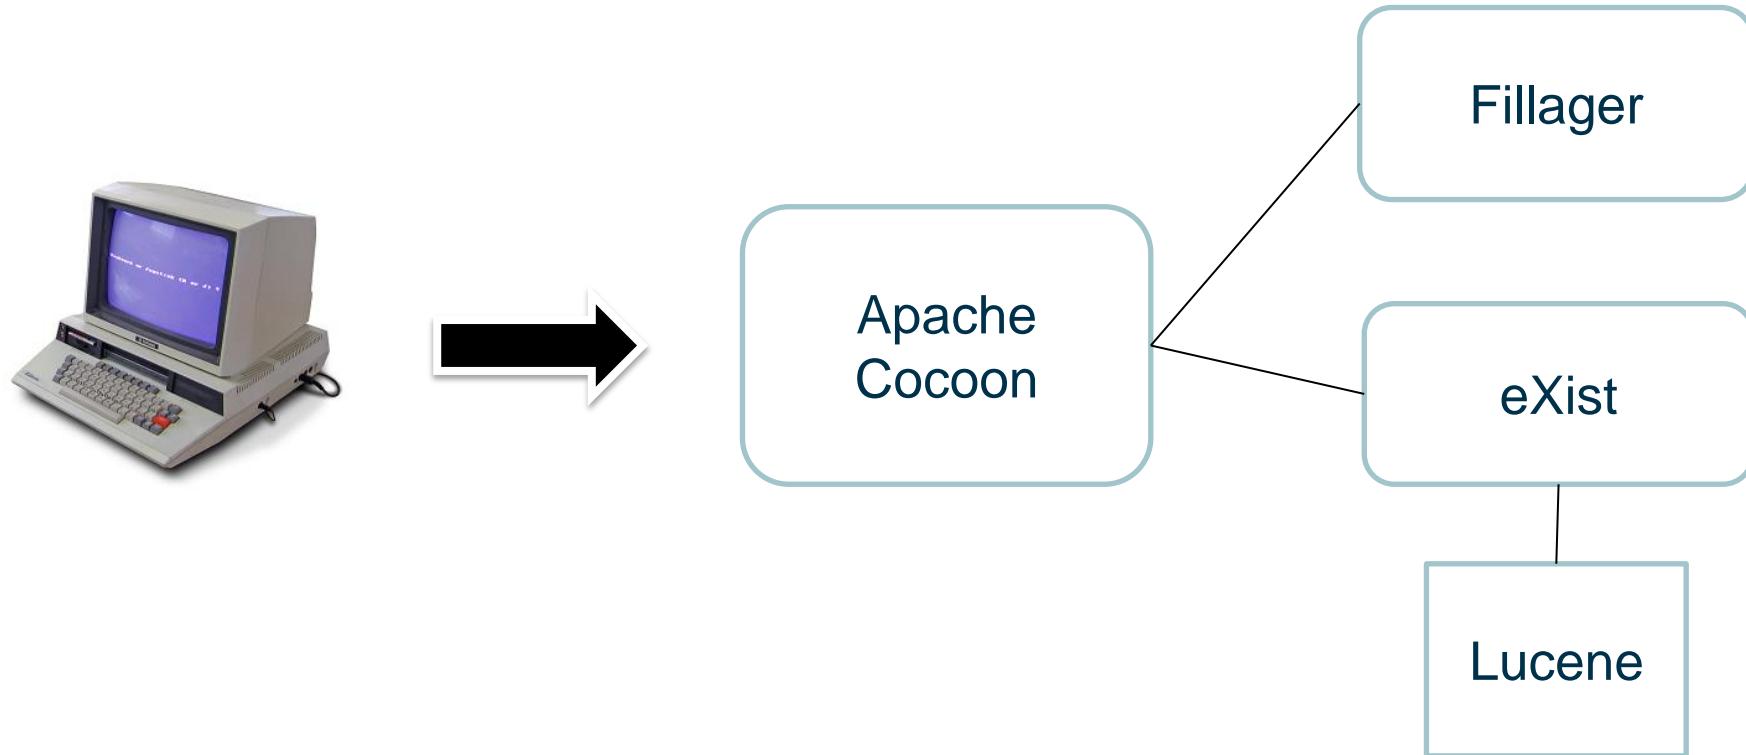
Ressursnavn	Fagområde	Termposter	Språk
<b>KB-N</b>	økonomi/administrasjon	8.473	N/E
<b>Mikroøkonomen</b>	mikroøkonomi	798	N/E
<b>NHH Termbase</b>	økonomi/ administrasjon	2859	N/E
<b>UHR</b>	studieadmin. term.	3351	N/E
<b>NOT</b> (Norsk termbank)	oljeterminologi ++	30.525	N/E
<b>RTT</b>	tekniske fagområder	48.311	N/E
<b>LTW</b>	språkteknologi	105	N/E
<b>SprakTek (NorskDok)</b>	språkteknologi	83	N/E
<b>Maritim ordbok</b>	maritime fag	1.226	N/E
<b>Totalt</b>		<b>92.389</b>	

# Konverteringsarbeidet

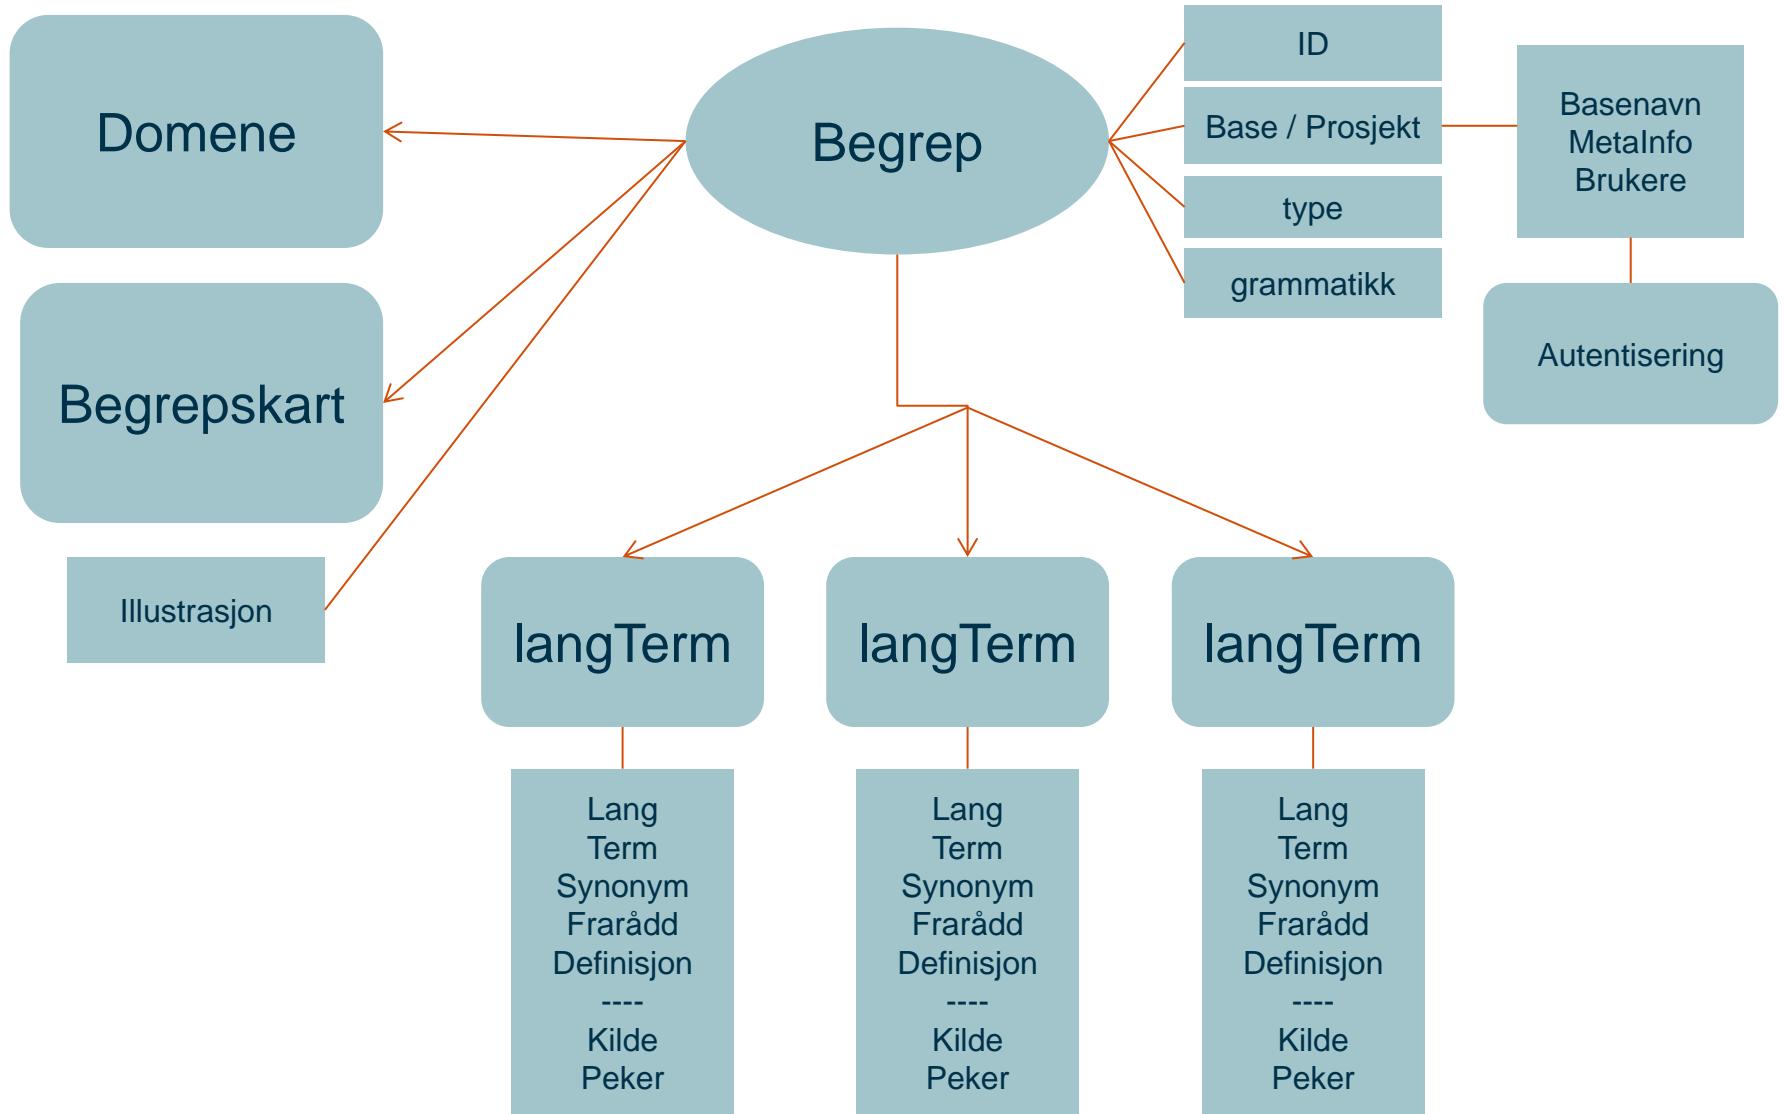




# Demoversjonen - infrastruktur



# Datamodell





# Resource integration

NHH

CLARINO | CLARINOrkt

## Termportalen

Forsiden Søkeside Om Termportalen Termbasene Om CLARINO Publikasjoner

Du er her: [Forsiden](#) > [Termbasene](#) > [Mikroøkonomien](#) > mikro-535

term sealed-bid auction  
def auction market in which all bids are made simultaneously in sealed envelopes, the winning bidder being the individual who has submitted the highest bid

term auksjon med lukket engangsbud

takeover **bid**

KBN: kbn-3438 (eng) [term]

current **bid** price



# bid

- What the dictionary will tell you

■ **bid** (subst.) bud, tilbud, anbud, melding, forsøk (Stor engelsk-norsk)

(br.) (am.) offer certain price for something, especially at auction  
(br.) (am.) utter greeting or farewell to

**bid<sup>1</sup>** subst. /bɪd/

**1** (auksjon) bud

**EKSEMPEL** • *my highest bid will be £100* mitt høyeste bud blir 100 pund

**2** (handel) tilbud, anbud

**3** (kortspill) bud, melding

**4** forsøk

**EKSEMPEL** • *the prince made a bid for the throne* prinsen gjorde et forsøk på å bli konge

**5** (hverdaglig, amer.) innbydelse, invitasjon

**UTTRYKK**

make a **bid** for something gjøre alt for å vinne noe, være ute etter noe

no **bid** (kortspill) pass

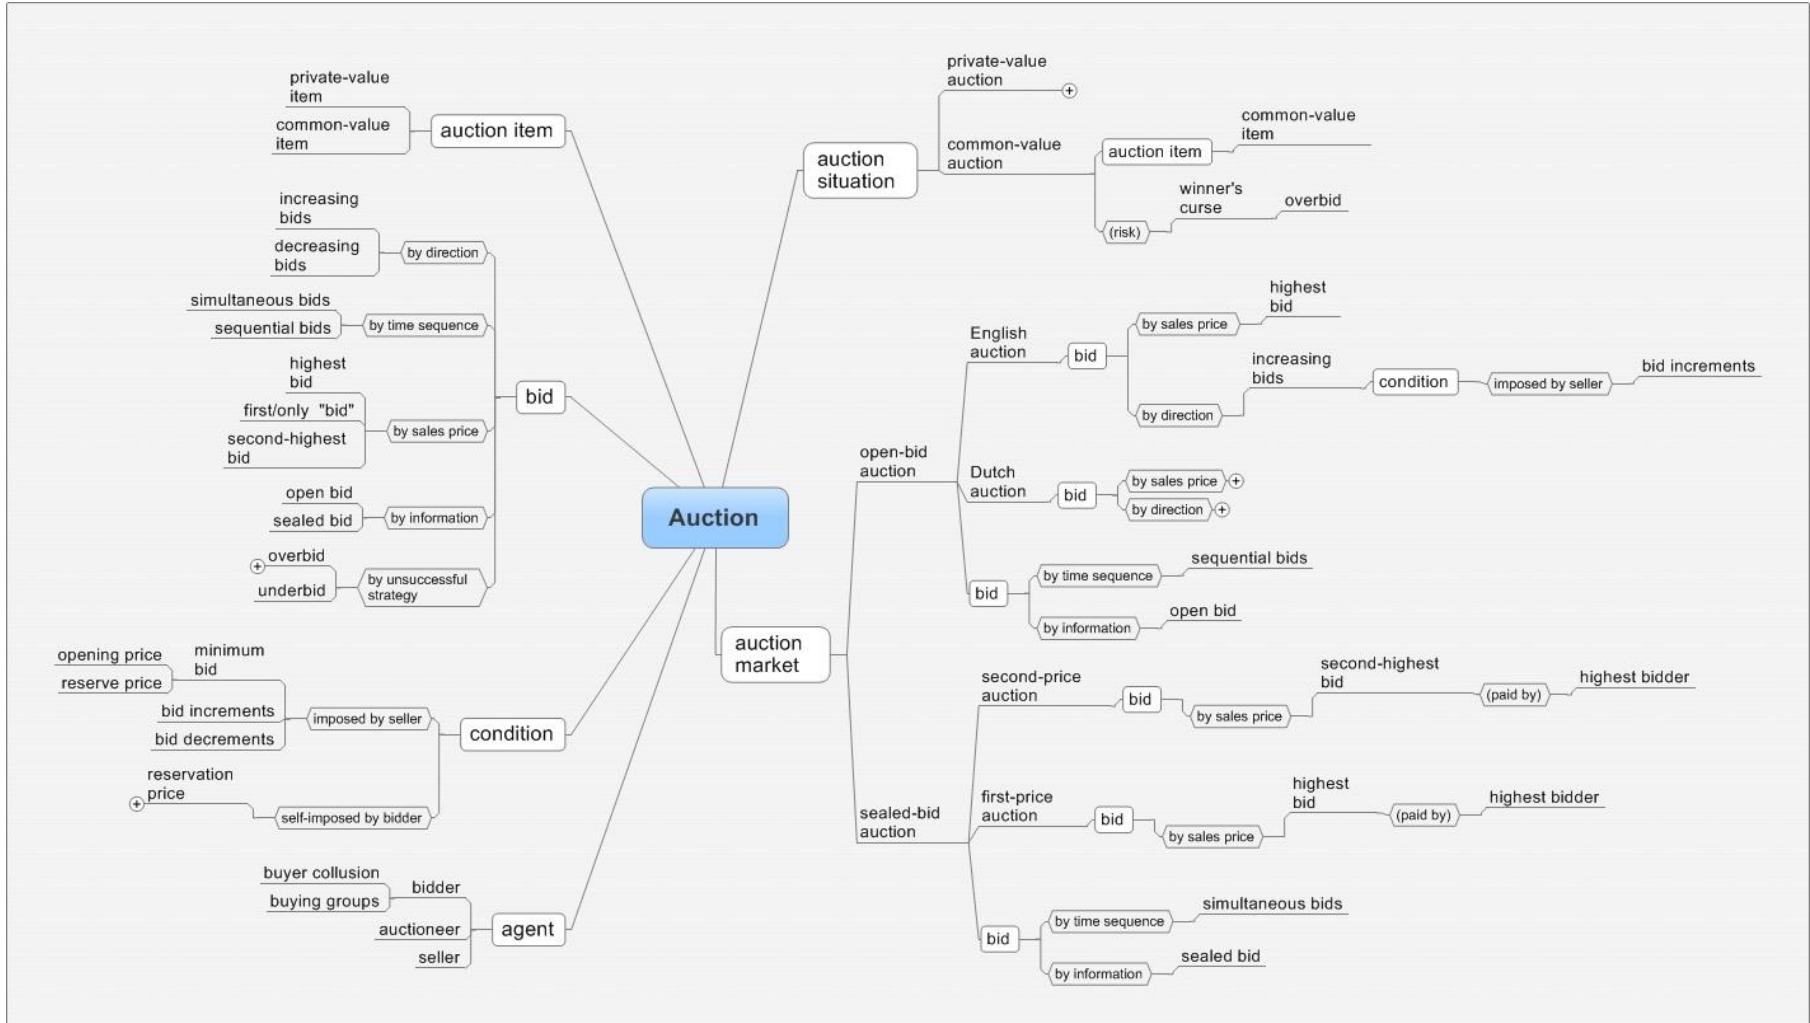
win the **bid** få tilslaget

Publikasjon: Stor engelsk-norsk

[Send en kommentar til denne artikkelen.](#)

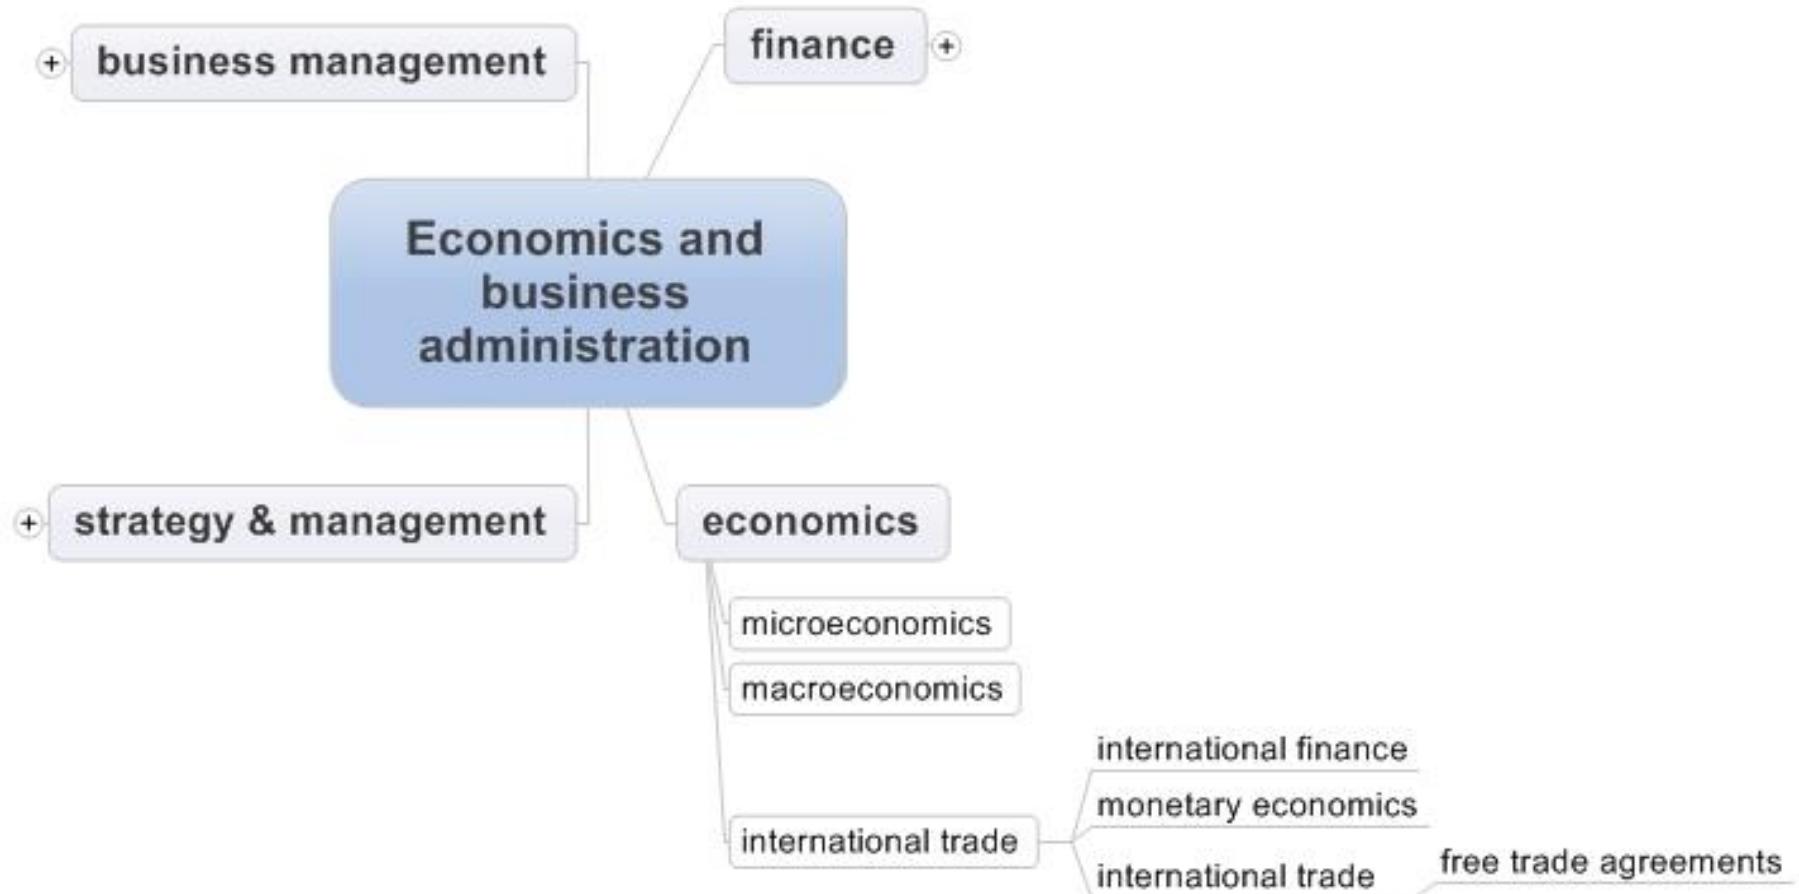


# Conceptually structured data (ontologies)





# Domains and subdomains





# The lexicographical approach

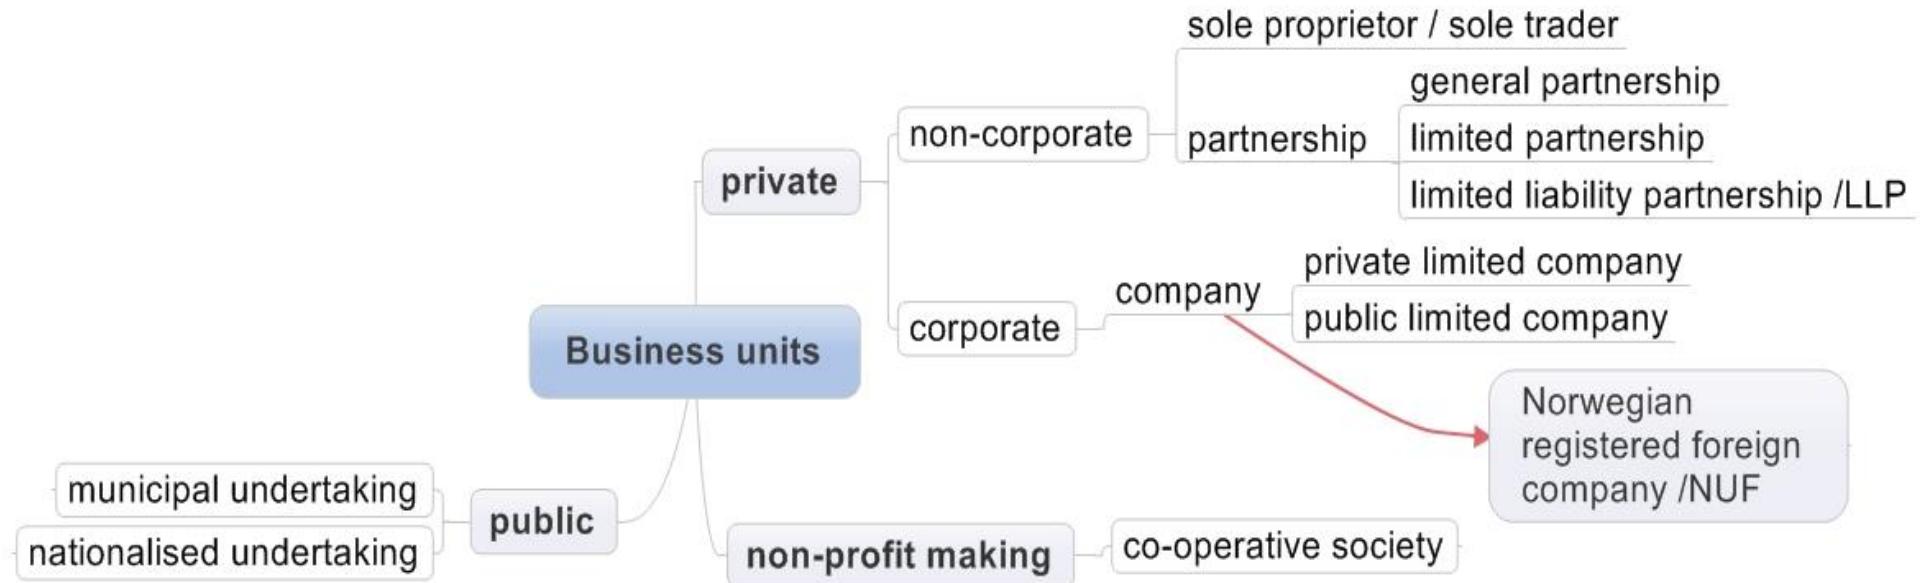
■ **selskap** (subst.) society, company, companionship (Stor norsk-engelsk)

**selskap** *subst. n*

- 1 (samvær) society, company, companionship
- 2 (festlig sammenkomst) party
- 3 (festdeltakere) company, party
- 4 (økonomisk foretak) company, corporation (*amer.*)
- 5 (gruppe personer) party
- 6 (forening) society, association
- 7 (skuespillertrupp) company
- 8 (samfunnslag) society



# Terminology





# Resource integration and use cases

- CLARIN federated content search
  - Incoming/outgoing
  - Downloading of whole TBX termbases
  - Direct access to terminological information in term posts
- Added value for Terminologi.no
  - Links to corpus search, e.g. Norsk aviskorpus (and vice versa)
  - Morphosyntactic information from Norsk ordbank
  - Decomposition of composita from Oslo-Bergen tagger
  - Parse trees from INESS
- Added value for CLARIN(O) users generally
  - Exploitation of terminology resources for various technology purposes
  - Integration into multilingual/semantic application
  - WordNet, WSD, MT, ontology engineering, etc.



# Challenges

## Technology

- Integrating data into CLARIN repositories
- Integrating other resources into Termportalen
- Visualisation: dynamic (on-the-fly) generation of concept diagrams (3D, zoomable)

## Content

- Domain/subdomain classification of resources lacking this info
- Updating content