

Adelheid

A Distributed Lemmatizer for Historical Dutch

Hans van Halteren, RU Nijmegen, hvh@let.ru.nl
Margit Rem, RU Nijmegen, M.Rem@let.ru.nl
Daan Broeder, MPI Nijmegen, Daan.Broeder@mpi.nl

Overview

Topic

- Clarin NL demonstrator project
- Tagging and lemmatizing historical text

Structure

- Functionality of the software
- Activities during Adelheid

Software: Task

Conci allen hiden dat dy lantiercine del weeghe en lande herte hinsaerme meeste van der prachien
van sente gheue pubuerde kunnen dat dy antien hebbe chins der me schoef ms sepeno binante
om bruegham vnlucttan Anten jns dachet was om stroembeke die te bruegham yn sente jans
hof waent den hinsaerde hofstat yn aldiere memeren dat gheleghen es yn de prachien van houtenbeke
nenen jans bastaerts hof. En wort meer noch een dachwant en vnu en twentech huuden lants
luctel meer oft men. Welckant hent gan vanden perreghelte dat gheleghen es op dat minne
sude neren jans meysa lant en in dander fide nenen jan traestalant. En syn hier tuc comen bi
mannghen sneyere en bi vnsome der sepenen ghelyc dat de sepenen tre spret diere op
ghemact es en die dy re ons veert hebbie. Wout dat dy hinsaerme meesteren ghenaept
ghelouen vor ons en voore ense natcomelinghe als van der verseide hinsaerme weghe
Raetbiertan van stroembeke lyst voore ghenoept inde kerke van sente goedelen voer kerke erster
twentech stollinghe dorfghelte altoes te her sonode te betachte ten wile te hulpe dienen den
gheney gheest te drukken die ronken he ghelewest hebben / met sellen condicien waert also
dat die waren ghenaepte gaet. O gheerde oft af name in dreyer memere. sadat wy den soms
met overghen en condensand dese vorst kerke oost en staide hulpen gheden en drachten na
na do gracie van den seindie siere jaerter op herst altoes sonden en gheleist. En ome dat die
wout en ghescrede blinen sal ghelyc dat waren bescreuen tre schelten van hinsaerme gepte
waren ghenaept enser hinsaerme ghehalde dese tre ghehanghen in kynnen dorwaerheit
Die was ghedien mit ghetont hen als men spreft. az. cit. sess. en trestech. xxij daghe in
de maent van januarij.

Software: Task

Input: Transcription

C108p39304 Blok862 gecollationeerd.280394.HD

wy borghermestere ende raet van groninghen bekennen ende betughen met
dezen openen breue dat vor ons quam ghelmer storm ende becande dat hie heft
vercoft rodetiden vyertyendehalf gras landes met al horen to behoren vor ene
summe gheldes de ghelmer vorseit vol ende al betaelt js ende deze vy
ertyendehalf gras landes vorseit droech ghelmer vorseit vp rodetiden vorseit
ende sinen erfghenamen vrij ende quiit met allen rechte ende eghendome
eweliken to bruken ende to besitten dit vorseide land js gheleghen in lywerder
wolt vp de noerd zide van den wolt graue daer viif grase landes van gheleghen ziin
by rodetiden erue vorseit dat an de oester zide leghet ende viif graze landes daer
tette mellens erue by gheleghen js an de oester zide ende vyerdehalf gras landes
an de noerd zide van den vorseiden viif grases daer een sloet en tuschen gaet dat
or kunde wy met onser stad seghel . ghegheuen jnt jaer ons heren dusent
drehondert dre ende neghentich vp sente nycholaus auond do wicbolt euerdes
euerd sickinc johan van den berghe ende jacob schelleghen borghermestere waren
onser stad

Software: Task

Output: tags and lemmas

- tags from a reasonably complex tagset
 - based on corpus van Reenen – Mulder
 - 184 **basic** tags, plus **combination** tags for enclitic forms

Token	Tag	Lemma
och	Conj(coord)	of
en	Adv(neg)	en
betalden	V(fin,past,lex,formn)	betalen
tesen	Adp()+Pron(dem,formn)	te+deze
vorsprokene	Adj(formn)	voorgesproken
tide	N(sing,forme)	tijd
.	Punc(lp)	.

Software: Stages

- Tokenization
 - Reinterpretation of word separation
- Potential tag/lemma assignment
 - Lexicon lookup
 - Known forms
 - Expected variant forms, on basis of known variation
 - Unknown word handling
 - Machine learning
 - Nearest neighbours in expanded lexicon
- Contextual disambiguation

Software: Stages

- Tokenization
- Potential tag/lemma assignment
- Contextual disambiguation: Combination
 - SVMTool: Support Vector Machines
 - TnT: Hidden Markov Models
 - WPDV: Distribution of contextual features
 - All with left-to-right and right-to-left tagging

Software: Quality

10-fold cross-validation on van Reenen-Mulder

Recall for single best tag/lemma

- Token: 99.1%
- Tag: 94.9%
- Lemma: 93.9% or 94.8%
 - Higher percentage with test token adaptation
 - Computationally expensive

Adelheid: Software

Integration into Clarin infrastructure

Aspect	Currently	Adelheid
User interface	<i>Linux command line</i>	Web application
Activating core software	<i>Linux shell scripts</i>	Web service(s)
Core software	<i>Linux binaries, Perl scripts</i>	<i>Linux binaries, Perl scripts</i>
Disambiguation data	<i>Software determined</i>	<i>Software determined</i>
Internal data streams	<i>Ad hoc</i>	XML, ISOcat compliant
Input/output formats	<i>Ad hoc</i>	XML, ISOcat compliant
Lexicon formats	<i>Ad hoc</i>	XML, ISOcat compliant
Lexicons	<i>(Expanded) charter</i>	<i>Charter + User provided</i>

Adelheid: For the User

Demonstrator scenarios

- Tagging texts with basic system
- Tagging texts with additional own lexicon

Documentation

- Texts
- Tags and lemmas
- Workings and use of the system

Questions?

Later... ?