



# Apolda

## *A Practical Tool for Semantic Annotation*

Christian Wartena  
Rogier Brussee  
Luit Gazendam  
Willem-Olaf Huissen

*Telematica Instituut*  
*Enschede*  
*The Netherlands*



# Overview

- Introduction: concepts in texts
- Problem
- Approaches
- Gate/Apolda
- Applications



# Introduction: concepts in texts

- Find occurrences of ontology concepts in a text
- Problems
  1. Spelling variants, inflection, encoding, etc.
  2. Synonyms
  3. Homonyms/Ambiguity
  4. Concept is 'present' but not mentioned
- Problems 3 and 4 scientifically very interesting
  - Problem 1 often underestimated and solved in a ad-hoc manner



# Typical problems

- Encoding 'special' characters
- Capitalization
  - Concepts in ontology often capitalized!
  - *Typical = typical* (in title or sentence beginning)
  - *die Deutsche Bank* ≠ *eine deutsche Bank*
  - *national aeronautics and space administration* = *National Aeronautics and Space Administration*
- Inflection
  - *Museums = museum*
  - *British museums* ≠ *British Museum*
- Interpunction
  - *Art-works* ≠ *Art – works*
    - as in “The Metropolitan Museum of Art - Works of Art”



# More Problems

- Synonymy
  - Especially names
    - *Bill Clinton, William Jefferson Clinton, William J. Clinton, governor Clinton, president Bill Clinton, president Clinton, Mr. Clinton, Clinton, W.J.*
- Multiword Expressions



# Level of Abstraction

- At which level should look for concepts?
- Matching at high-level of abstraction
  - Consider text as a list of tokens or even lemmas
  - Advantage: No problems with line breaks, encoding, etc
  - Disadvantage: Loss of essential information
- Matching at low-level
  - Consider text as character sequence
  - All information directly available
  - No dependency on other analysis tools
  - But: lot of basic problems to solve



# Approaches for detecting concepts

- Lexicalized ontologies
  - Easy to use in small projects
  - Easy to maintain
- Extending lexical resources with references to ontology
  - Natural separation of lexical and ontological knowledge with clear interface
  - Problematic for multiword expressions
    - If they cannot be motivated from the lexicon
- Many project specific solutions



# Apolda

- **A**utomated **P**rocessing of **O**ntologies with **L**exical **D**enotations for **A**notation
- General open source solution
- For Lexicalized ontologies
- Concentrate on detecting all mentioned concepts
  - Leave all disambiguation to other tools





# General Solution

- GATE plugin
- GATE:
  - General Architecture for Text Engineering
  - “an architecture, a free open source framework (or SDK) and graphical development environment”
  - Developed by NLP group of Sheffield University
  - <http://gate.ac.uk/>
- Apolda download:
  - <http://apolda.sourceforge.net>





**GATE**

- Applications
  - trefwoorden
- Language Resources
  - rembrandt
  - ISO
  - vanGogh3
  - vanGogh2
  - vanGogh1
  - test
  - wikiSchilderkun
- Processing Resources
  - names
  - wikiwoorden
  - apolda
  - orth+
  - tag+
  - tag

Messages trefwoorden

Loaded Processing resources

Na...	T...

Navigation arrows: >> <<

Selected Processing resources

!	Name	Type
	reset	Document Reset PR
	tokenize	GATE Unicode Tokeniser
	split	ANNIE Sentence Splitter
	tag	TreeTagger
	tag+	Jape Transducer
	orth+	Jape Transducer
	apolda	Apolda Ontology Annotator
	wikiwoorden	Jape Transducer
	names	Jape Transducer

Navigation arrows: ↑ ↓

Corpus: test

The **corpus** and **document** parameters are not available as they are automatically set by the controller!

Parameters for the "apolda" Apolda Ontology Annotator

Name	Type	Required	Value
inputASName	java.lang.String	<input type="checkbox"/>	<input type="text"/>
lemmaFeature	java.lang.String	<input type="checkbox"/>	lemma
outputASName	java.lang.String	<input type="checkbox"/>	<input type="text"/>

Run


Serial Application editor

Initialisation Parameters

# Lexicalized Ontologies

- Using Gate's OWLIM ontology interface
  - Supports RDF/OWL, turtle, ntriples
- Expects explicit definition of textual representations (as annotation properties)
  - If no such labels are present identifiers are used
  - Deals with two different labels
  - If more than 2 types of labels are used make them `rdfs:subProperty` of one property.
- Supports different representations for different languages.






**GATE**

- Applications
- Language Resources
- artists**
- Processing Resources
- Data stores

Messages

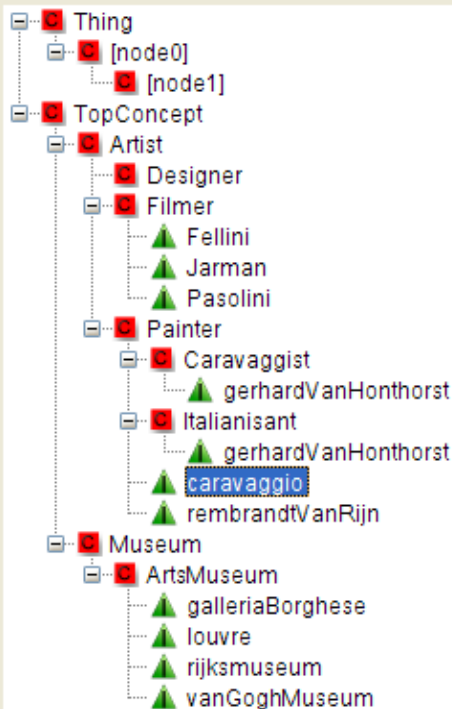
artists



Classes &amp; Instances

Properties

Classes and Instances



## ▼ Resource Information

▲ caravaggio  
 URI <http://www.owl-ontologies.com/unnamed.owl#caravaggio>  
 TYPE Ontology Instance

## ▼ Direct Types

■ Painter

## ▼ All Types

■ Painter  
 ■ TopConcept  
 ■ Artist

## ▼ Same Instances

## ▼ Property Types

▲ altTextualRepresentation [ALL RESOURCES]  
 ▲ transitiveOver [ALL CLASSES]  
 ▲ prefTextualRepresentation [ALL RESOURCES]  
 ▲ title [ALL CLASSES]  
 ▲ seeAlso [ALL RESOURCES]  
 ▲ comment [ALL RESOURCES]  
 ▲ isDefinedBy [ALL RESOURCES]  
 ▲ versionInfo [ALL RESOURCES]  
 ▲ label [ALL RESOURCES]

## ▼ Property Values

▲ altTextualRepresentation Caravaggio  
 ▲ altTextualRepresentation Michelangelo Merisi  
 ▲ prefTextualRepresentation Michelangelo Merisi da Caravaggio

GATE Ontology Editor Initialisation Parameters



GATE

- Applications
  - trefwoorden
- Language Resources
  - rembrandt
  - ISO
  - vanGogh3
  - vanGogh2
  - vanGogh1
  - test
  - wikiSchilderku
- Processing Resources
  - names
  - wikiwoorden
  - apolda
  - orth+
  - tag+
  - tag

Messages trefwoorden rembrandt

Annotation Sets Annotations Co-reference Editor Ontology Text

## BEELDENSTORM

Aflevering over Rembrandt

In deze aflevering wordt 'het probleem Rembrandt' besproken. Dit gebeurt aan de hand van diverse schilderijen van Rembrandt van Rijn en schilderijen die aan hem werden toegeschreven.

Presentator Van Os geeft een voorbeeld van een schilderij dat uiteindelijk niet van Rembrandt bleek te zijn en legt uit waarom de aandacht voor vroeger werk van Rembrandt in een bepaalde periode weinig werd gewaardeerd.

oe	...	St...	End	
cion		29	38	{class=Rembrandt_van_Rijn, identifier=Rembrandt_van_Rijn, ontology=file:/D:/JDev/
cion		79	88	{class=Rembrandt_van_Rijn, identifier=Rembrandt_van_Rijn, ontology=file:/D:/JDev/
cion		154	172	{class=Rembrandt_van_Rijn, identifier=rembrandt_van_rijn, ontology=file:/D:/JDev/C
cion		154	172	{class=Nederlands_kunstschilder, identifier=rembrandt_van_rijn, ontology=file:/D:/JL
cion		154	172	{class=Rembrandt_van_Rijn, identifier=Rembrandt_van_Rijn, ontology=file:/D:/JDev/
cion		308	317	{class=Rembrandt_van_Rijn, identifier=Rembrandt_van_Rijn, ontology=file:/D:/JDev/
cion		385	394	{class=Rembrandt_van_Rijn, identifier=Rembrandt_van_Rijn, ontology=file:/D:/JDev/

7 Annotations (0 selected)

Document Editor Initialisation Parameters

- Mention
- Sentence
- SpaceToken
- Split
- Token
- Trefwoord

▶ Original markup:

New



**G GATE**

- Applications
  - Demo MultimediaN
- Language Resources
  - Westfries Museum
  - Wiki Kunst
  - Demo Corpus
- Processing Resources
  - Apolda
  - Dutch Tree Tagger
  - tokeniser
  - split
  - reset
- Data stores

oe	▼	text/
of recognized concepts	▼	19
of tokens	▼	610
orceURL	▼	file:/t
	▼	

Messages Demo MultimediaN Westfries Museum

Annotation Sets Annotations Co-reference Editor Ontology Text

In 2003 benaderde Maurice Heerdink vijf mensen met een verzoek of hij ze mocht portretteren. Vijf mensen waar hij een persoonlijke waardering voor heeft. Vijf theatercoryfee?n. Vijf mensen in het licht van de schijnwerper.

Ellen Vogel, Jenny Arean, Willem Nijholt, Johnny Kraaijkamp en Aus Geidanus jr.

Tot zijn vreugde waren alle vijf direct bereid mee te werken, al was het niet altijd eenvoudig een afspraak tot stand te krijgen. Gedurende twee en half jaar werkte Heerdink aan de totstandkoming van deze serie. Aus Geidanus jr. vertelde dat hij een tijd lang sprakeloos naar het eindresultaat had staan staren. Ellen Vogel stuurde meteen een bedankkaartje: leuk geworden. Johnny Kraaijkamp vroeg om een uitnodiging als het werk tentoongesteld zou worden.

Het Westfries Museum heeft de primeur deze theater portretten als eerste te exposeren als onderdeel van de overzichtstentoonstelling van het werk van Maurice Heerdink: In het Licht Van De Schijnwerper.

Tijdens zijn opleiding aan de Haagse Koninklijke Kunst Academie raakte Heerdink gefascineerd door de dramatiek van het licht. Be?nvloed door de Film Noir plaatste hij zijn modellen in een spotlicht om een zo intens mogelijk beeld te cre?ren. Jarenlang was de film zijn belangrijkste inspiratiebron. Toen hij de werken van Caravaggio leerde kennen ontdekte hij de enorme invloed van de belichting in deze schilderijen op de westerse cultuur. De invloed was terug te vinden bij filmers als Pasolini, Fellini en Jarman. Heerdink concludeerde dat hij een hedendaagse Caravaggist is. In het jaar van de grote tentoonstelling van Rembrandt en Caravaggio toont Heerdink voor het eerst zijn schilderijen over de Griekse Mythologie en de Bijbel. ?De tragedies van Prometheus, Icarus en de heilige Sebastiaan zijn tijdloos en fantastisch om uit te beelden.? Daarnaast exposeert hij een reeks persoonlijke werken, waarin Het Mannelijk Lichaam centraal staat. Ook hierbij draait het om de belichting. Door middel van strijklucht gaat hij op zoek naar het ultieme reli?f van spieren.

Bij het bereiken van een halve eeuw en als vervolg op de theaterserie begon Heerdink dit jaar aan een nieuw hoofdstuk: De Zelfportretten. Niet geijkt met penseel voor een spiegel, maar dreigend, dramatisch en theatraal. In 2005 hield het Westfries Museum in het prentenkabinet een kleine tentoonstelling van schilderijen en tekeningen van Heerdink onder de titel: VOC en VERRE VOLKEN. Op een geheel eigen wijze maakte Heerdink een serie over de Maya cultuur, waarin hun iconografie centraal staat. Daarnaast ontstonden in de loop der jaren werken over Indianen en Azi?. Een deel van deze werken zullen nogmaals

Document Editor Initialisation Parameters

Ontology Tree(s) Options

Wiki Kunst ▼

- Stripfiguur
- Afbeelding\_kasteel
- Japans\_striptauteur
- Franse\_stripreeks
- Afbeelding\_naar\_onderwerp
- Spaans\_kunstschilder
- Lucky\_Luke
- Schilderkunst
- Hellenistische\_schilderkun
- Schilderij
- Oud\_Griekse\_schilderkun
- Etruskische\_schilderkunst
- Moderne\_kunst
- Schilderkunst\_van\_de\_20e
- Schilderkunst\_van\_de\_21e
- Kunstschilder
- Gotiek
- Schildertechniek
  - horizon\_\_perspectief
  - penseel
  - passepartout
  - onderschildering
  - impasto
  - paletmes
  - schildersmateriaal
  - terpentijn
  - plafondstuk
  - grisaille
  - verkorting
  - schildersezel
  - gouache
  - palet
  - lichaamsverhoudinger
  - stofuitdrukking
  - horror\_vacui

# Matching

- Match all textual representations, including overlapping ones
  - Exception: overlap of representations of same concept. E.g. *Rembrandt / Rembrandt van Rijn*
- Match case insensitive, literal strings, normalized strings and lemmas
- Match only literal strings if quotation marks are used
  - (Remember the different matching levels)



## Be cautious

- Reusing existing resources is always problematic
- Example:
  - Ontology of category structure, articles and redirects from wikipedia
  - Lemmatization
  - “*landden*” (*landed*) → lemmat. → “*landen*” (to land)
  - “*landen*” (*countries*) → Apolda → “*land*” (*country*)
  - “*landden*” (*to land*) • “*land*” (*country*)





# Applications

- MultimediaN Video Tagging Project at Telematica Instituut
- Catch project at Dutch Institute for Sound and Vision
  - Keyword extraction from descriptions of videos
- Other, e.g. Master thesis project at Rotterdam University.
- About 140 downloads



## 'Cataloguing pipeline for TV-programs using Apolda'

- RDF\OWL representation of cataloguers ontology enriched with singular/plural form, synonyms, alternative spellings etc.
- collect textual resources related to the TV-program
- Use Apolda to highlight concept from the cataloguers ontology.
- Use TF.IDF and ontology relationships between found concepts to identify the semantically most relevant concepts in the texts.
- Recommend these concepts for the catalogue description of the TV-program.






Debug: Tag



### Video - Wie was Filippo Brunelleschi?



**Titel :** Wie was Filippo Brunelleschi?

**Datum :** 4-10-06 16:49

**Duur :** 00:02:05  
(hh:mm:ss)

**Beschrijving :** Filippo Brunelleschi (1377-1446) was een Italiaans architect. Hij was zijn tijdgenoten ver vooruit en wordt historisch beschouwd als zeer belangrijk voor de architectuur. Zo bouwde hij bijvoorbeeld de beroemde koepel van de Dom in Florence. Schrijver Ross King weet veel over hem. In dit fragment vertelt hij bijvoorbeeld dat Brunelleschi zeer veelzijdig en geleerd was. Van oorsprong was hij goudsmid, maar hij werkte met brons. Als schilder vond hij het perspectief (dieptewerking) uit. Daarnaast bestudeerde hij literatuur en schreef hij poëzie. Ross King schreef het boek "De koepel van Brunelleschi", over de bouw van de Dom in Florence. Midas Dekkers sprak daar met hem over. Ook professor Massimo Ricci vindt Brunelleschi een genie. Hij beweert zelfs dat de nog beroemdere Leonardo da Vinci (1452-1519) enkele ontwerpen van hem heeft overgenomen.

Mijn Tags:

Alternatieve Tags:

Tag suggesties:

- grottekening
- boek
- point
- schilderen
- Brunelleschi
- koepel
- de schilderkunst
- montage
- ...

# Summary

- Find representations of concepts in a text
- Inventarisation of problems
- Implementation of a general solution
- Available for a widely used framework
- Usefull in several projects

