

Text Mining for Historical Documents

Motivation and Case Studies

Caroline Sporleder

Computational Linguistics/MMCI
Universität des Saarlandes

Wintersemester 2011/12

22.02.2012

Museums, archives and libraries possess large collections of data

- artefacts
- books, manuscripts
- meta-data: catalogues, field books, reports etc.

More and more digitisation projects

- governments have come to see CH as a valuable asset
- digitised data can be accessed more easily
- digitisation as a safeguard against data loss

Digitisation offers opportunities

- easier data access (searching, browsing)
- presentation of data (visualisation)
- knowledge discovery
- support for curation (partial automation, consistency checking)

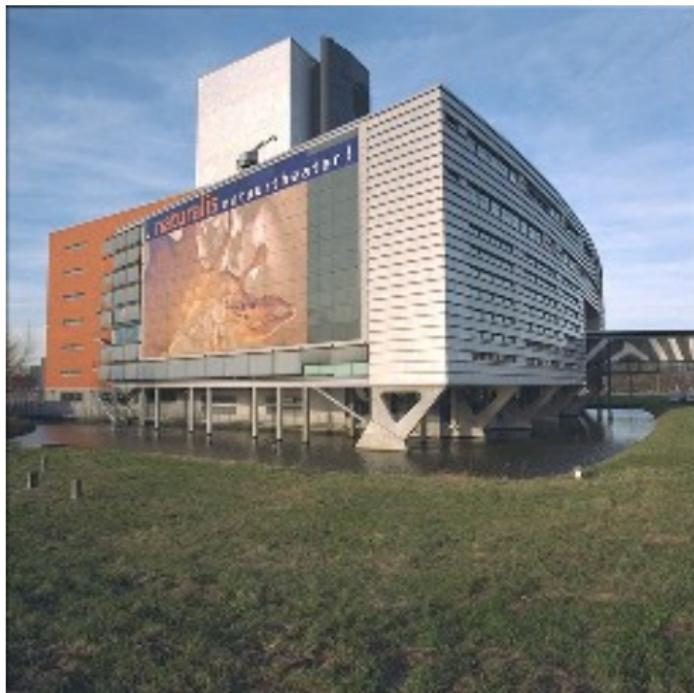
But to make the most of digitised data, we need sophisticated tools

- information retrieval (data indexing and searching)
- information extraction (linguistic data analysis)
- automatic data linking
- discovery of trends and interdependencies
- data presentation (for experts and non-experts)
- meta-data enrichment (linguistic disambiguation, semantic tagging, automatic transcription of audio data etc.)
- semi-automatic curation (data completion, error detection, consistency enforcement)

⇒ **text mining and natural language processing (NLP) play a big role because much of primary and most meta-data are textual**

Case Study: Naturalis

The Dutch National Museum of Natural History



Naturalis: The Collection (1)



- more than 10 million specimens:
 - 5,250,000 insects
 - 2,290,000 invertebrates
 - 1,000,000 vertebrates
 - 1,160,000 fossils
 - 440,000 stones and minerals
- 150,000 species
- 10% of the Earth's biodiversity

Naturalis: The Collection (2)



For each of the 10M specimens

- a label attached to the specimen, providing basic details (biological name, where and when found, inventory number)
- an entry in a register book
- usually an entry in a field book

Additionally, for many specimens

- an entry in a specimen data base
- a photo
- meta-data in the form of research papers etc. written about them

Also:

domain ontologies, taxonomic descriptions, maps etc.

Convert field and register books into data bases

- take high quality digital photos of pages
- transcribe them manually

Digitisation of Fieldbooks

- Foto II, opnames 18 blm 37 van de no's 15 t/m 22
RMNH 15034
- Reg.nr. 15139 → 17 RMNH 15480
- RMNH 15690
- Uitgenomen noo: gevuld met Paris
Voorzien van A, B, C, D, E en f.
- Reg.nr. 15230 top lang blauw, rest roze → RMNH 15245
- Reg.nr. 15700
- Reg.nr. 16738 → RMNH 16207
- RMNH 16293
- 299, onderkant stamt oranje
- naam eerbij: Parakaimana.
15. Gonatodes humeralis, 3-V-1968, Cultuurtuin, Paramaribo, op een stamme van bomen, juist boven grond o.a. karkantrie, palmboom, boom met paarse vruchten aan stam. ± 9.30 - 16.30. Eetje aan basis stam.
= cacao
16. Ameiva a. ameiva. Cultuurtuin, Paramaribo, 3-V-1968, wegberm, tussen gras, onder steen. ± 10 u.
17. Cnemidophorus lemniscatus, Cultuurtuin, Paramaribo, 3-V-1968, wegberm tussen gras, onder steen. ± 10 u.
18. Anolis auratus, Cultuurtuin, Paramaribo, 3-V-1968, wegberm, lage kruipende vegetatie, tot 50 cm hoog. ± 10 u.
19. Gymnophthalmus speciosus, Cultuurtuin, Paramaribo, 3-V-1968, onder afgevallen blad van boom met paarse vruchten aan stam,
onder en vermoedelijk ook in vermolmde boomstammen.
9.30 u - 12 u zeer talrijk, 15.00 - 17.00 u minder talrijk, zonnebad
op o.a. plankwortels karkantrie.
20. Cercosaura ocellata, Cultuurtuin, Paramaribo, 3-V-1968,
onder afgevallen blad en gemaide Tradescantia, licht bos, boom.
21. Hyla rubra, Cultuurtuin, Paramaribo, 3-V-1968, op stam van boom met paarse vruchten aan stam (=cacao)
22. Lepidodactylus sybodedylus (det. Dr. A.B. Meek 1972) Cultuurtuin, Paramaribo, 3-V-1968,
tussen afgevallen blad van boom met paarse vruchten op stam
11.30 u. Naar grote (± 2m) sprongen.
23. Hemidactylus mabouia, Paramaribo, op buitenmuur huis o.a.d. Waterkant., 3-V-1968, ltd. F. Westerling.
24. Gonatodes humeralis, Paramaribo, Cultuurtuin, 4-V-1968,
op onderkantte boomstam.

Digitisation of Fieldbooks



Example: Typist Guidelines

	code	bladzijdennummer
A	1023 <u>Leptodactylus rugosus myersi</u>	242
	lens 117, v.lens 2. Bovenbankbreuk, 23-12-1980, 20.30-21.30 u., open granietplant met scherpe vegetatie, omgeving san- vannahes, zittend op graniet aan rand vegetatie, 10m.	
B	1024 <u>Hyla minuta</u>	142
	lens 120, 23-12-1980, 21.45 u., leek zittend aan rand van weg, op struik, 180 cm boven oppervlak van poeltje, secundaire has, 10 m.	
C	Waarnemingen Geleidelijk aanziltslaat Van 19 van Zandweg, 16 km W.van Wittegeen, weg naar Arunavara, dist. Saramacca, Suriname, 26-12-1980, 1600-1800 m, op weg in gebied met ondergelopen has, waarnemer H.S. Maagdenhout	1 [vrouw]

[lemma]
3023
Leptodactylus myersi
2 ex.
km 117, 4 km z Barubakreek, 23-ix-1980, 20.30-21.30u. Open granierplaats met schaarse vegetatie, omgeving savannenbos, zittend op granier aan rand vegetatie, 100m.

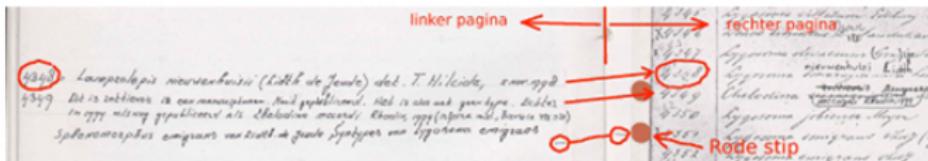
[lemma]
3024
Hyla Minuta
1 ex.
km 120, 23-IX-1980, 21.45 u. kwakend aan rand van weg, op struik, 180 cm boven oppervlak van poeltje, secondair bos, 100m

ex in slechte conditie, werd 's nachts opgegeten door *Leptodactylus rugosus* (3023) en volgende dag bij doden weer uitgebrakt. gedeeltelijk verteeld.

[lemma]
dia's 1980-XII. 2/4
Waarnemingen
Geochelone denticulata
1 [vrouw]
km 119 van Zanderij, 16 km W.van Witagron, weg naar Avanavero, distr. Saramacca, Suriname, 26-IX-1980, 9.00u, op wef in gebied met ondergelopen bos, waarnemer M.S. Hoogmoed.

...

Example: Typist Guidelines



Example: Typist Guidelines



5 | Parasitus fimetarius (Berl. 19) Nph. II dors. vent. Faure 1445 | RMNH Acari P3036 | in mest Weimar III.19

Transcription of Fieldbooks

- all fieldbooks relating to Reptiles and Amphibians Collection
- 15,000 handwritten pages
- manually transcribed by typists
- simple guidelines on how to deal with
 - non-ASCII characters
 - text written in the margins
 - illegible passages
 - etc.
- transcriptions completed in around 8 months
- <5% error rate

1 ex. *Phyllobates femoralis* At base of tree on small island, primary forest, 20.45-22.00 u. RMNH 23865

Lithodytes lineatus, Brownsberg, aan voet, onder stuk rot hout, 13.07.1968, 8.45 u., RMNH 26076

Dorsolateraal strepen heldergeel, tekening op dijen vuurrood, veel feller als bij *Phyllobates femoralis*.

Gonocephalus auritus Meyer, 3 ex. (1 juv.), Misool. Hoedt 1867.

RMNH 17656 *Eleutherodactylus zeuctotylus* 1 [vrouw] Lelygebergte, 4 km N.O. van airstrip, distr. Marowijne, Suriname, 19-VIII-1975, onder stuk hout, 610m, 1 [plus] d M. S. Hoogmoed.

What can you do with it? (1)

Database Fieldbooks Search

Registration Number	14655
Class	Amphibia
Order	Serpentes
Family	Colubridae
Genus	Psammophis
Species	sibilans
Sub Species	
No. of Specimens	1
Sex	
Storage Method	alcohol
Special Remarks	Geen verdere gegevens bekend.
Attribute	
Collector	Buttikofer, J.
Label Data	
Country	Liberia
Province/State	
Place	Schieffelins ville
Biotope	
Location	
Author	(Linnaeus, 1758)
Publication	
Printed	J
Globally Unique ID	(BB98DD11-4B3E-11D4-A2CB-00104BBC2C29)
Collection Date	- 1881
Collection Number	944
Country ID	132
Altitude	
Coordinates	
Determinator	
Determination Date	
Recorder	Grouw, H.J. van
Record Date & Time	2000-06-26
Inventory Number	0
Expedition	buttikoferliberia1881



What can you do with it? (2)

MITCH mBase
Using information texts from the cultural heritage

Psammophis sibilans

Database
Fieldbooks

Search

Results 1-8 of 8 for 'Psammophis sibilans'

14655 - Psammophis sibilans



Taxonomy : Amphibia - Serpentes - Colubridae - Psammophis - sibilans -
Location : Scheffelins ville, Liberia
Collection Date : > 1881
[Google Images](#) [Specimen Photo](#) [Google Image](#) [Wikipedia](#)

14652 - Psammophis sibilans

Taxonomy : Reptilia - Serpentes - Colubridae - Psammophis - sibilans -
Location : Robertsport, Grand Cape Mount, Liberia
Collection Date : 31-07-1881
[Google Images](#) [Google Image](#) [Wikipedia](#)

14649 - Psammophis sibilans

Taxonomy : Reptilia - Serpentes - Colubridae - Psammophis - sibilans -
Location : Grand Cape Mount, Liberia
Collection Date : 11-10-1881
[Google Images](#) [Google Image](#) [Wikipedia](#)

14653 - Psammophis sibilans

Taxonomy : Reptilia - Serpentes - Colubridae - Psammophis - sibilans -
Location : Robertsport, Grand Cape Mount, Liberia
Collection Date : 09-08-1881
[Google Images](#) [Google Image](#) [Wikipedia](#)

14654 - Psammophis sibilans

