

Taal- en Informatietechnologie

Emiel Krahmer &
Antal van den Bosch

{E.J.Krahmer,antalb}@uvt.nl

eerste semester 2003-2004

10/27/03

ABVI, Krahmer & Van den Bosch

1

Taal- en Informatietechnologie

- Informatietechnologie:
 - informatie halen uit tekst
 - samenvatten, classificeren
 - *slimme search engines*
- Taaltechnologie:
 - zinnen analyseren
 - dialogen voeren
 - informatie omzetten in tekst

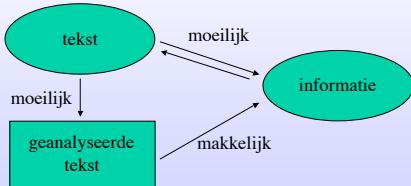
10/27/03

ABVI, Krahmer & Van den Bosch

2

Informatie en tekst

- Informatie zit verpakt in taal



10/27/03

ABVI, Krahmer & Van den Bosch

3

Over de cursus

- BDM/TKI
- 2001/2002 "Automatische bewerking en verwerking van informatie"
- colleges en open-boek tentamen
- twee bonustaken (1/2 punt per stuk)
 - informatietechnologie
 - taaltechnologie
- Blackboard
- <http://ilk.uvt.nl/~antalb/tint/>

10/27/03

ABVI, Krahmer & Van den Bosch

4

Over de cursus (2)

- dinsdagen 14.45 - 16.30 AZ01
- laatste college 2 december
- Emiel Krahmer, R104
 - E.J.Krahmer@uvt.nl
- Antal van den Bosch, R116
 - Antal.vdnBosch@uvt.nl

10/27/03

ABVI, Krahmer & Van den Bosch

5

Over de cursus: opbouw

- week 1: introductie
- week 2: basic NLP
- week 3: document retrieval
- week 4: information extraction
- week 5: NLP voor IE I
- week 6: NLP voor IE II

10/27/03

ABVI, Krahmer & Van den Bosch

6

Over de cursus: opbouw (2)

- week 7: text categorization
- week 8: text & web mining
- week 9: named entities & coreference
- week 10: question answering
- week 11: spraaktechnologie
- week 12: de praktijk: Textkernel

10/27/03

ABVI, Kraemer & Van den Bosch

7

Scope van de cursus

- Inzicht in state of the art in taal- en informatietechnologie
 - wetenschappelijk onderzoek
 - toepassingen
- Niet:
 - spraaktechnologie (zijdelings)
 - visuele informatietechnologie
 - bibliotheekwetenschappen

10/27/03

ABVI, Kraemer & Van den Bosch

8

Jackson & Moulinier

- “Natural language processing for online applications”
- NLP: analyse / synthese van gesproken en geschreven taal
- I.t.t. programmeertalen is NL **ambigu**
 - Visiting aunts can be a nuisance
 - She boarded the airplane with two engines

10/27/03

ABVI, Kraemer & Van den Bosch

9

NLP

- Informatieniveaus waarop ambiguïteit opgelost kan worden:
 - Syntax en semantiek
 - Pragmatiek en context (van gebruik)
- Twee visies:
 - Good old-fashioned AI, logica, formele/mathematische taalkunde
 - Statistische NLP en lerende systemen

10/27/03

ABVI, Kraemer & Van den Bosch

10

Rode draad

- Om accurate NLP te doen is **begrip** nodig
- Keuze:
 - **Diep** modelleren: is lastig (AI is erop kapot gelopen)
 - Oppervlakkig modelleren, korte bochten, trucs, **heuristieken**: werkt redelijk tot verrassend goed

10/27/03

ABVI, Kraemer & Van den Bosch

11

“Bluff your way into...”

- “Technologie” ~ toepassingen
- Informatietechnologie:
 - IR = information retrieval
 - IE = information extraction
 - a.k.a. text mining, web mining (analogie met data mining)
 - question answering
 - document classification

10/27/03

ABVI, Kraemer & Van den Bosch

12

Bluff your way into IR

- Relevante documenten vinden
 - zonder rommel ertussen (precision)
 - zoveel mogelijk (recall)
- Web search: grootschalig prutsen met booleaans zoeken
 - gebruikers accepteren lage p & r
 - "wonder" Google gebruikt *hubs & authorities* theorie
- Weinig taaltechnologie

10/27/03

ABVI, Kraemer & Van den Bosch

13

Bluff your way into IE

- Informatie halen uit tekst
 - zelfde precision & recall doel
- Text mining:
 - www.flipdog.com
 - Medisch voorbeeld (Swanson, 1991)

10/27/03

ABVI, Kraemer & Van den Bosch

14

IE: medisch voorbeeld

- Kennis uit titels medische artikelen
 - Stress is associated with migraines
 - Stress can lead to loss of magnesium
 - Calcium channel blockers prevent some migraines
 - Magnesium is a natural channel blocker
 - Spreading cortical depression (SCD) is implicated in some migraines
 - High levels of magnesium inhibit SCD
 - Migraine patients have high platelet aggregability
 - Magnesium can suppress platelet aggregability
- Magnesium deficiency ~ migraines!

10/27/03

ABVI, Kraemer & Van den Bosch

15

Bluff your way into web mining

- Analoog aan data mining
 - bier en luiers
- Tekst is informatie, maar slecht doorzoekbaar: omzetten naar DB
- Kennis opbouwen over domein
 - ...docent van cursus ...
 - ...ik volg de cursussen ...
 - ...lid van vakgroep ...
 - ...onderdelen van BAMA...

10/27/03

ABVI, Kraemer & Van den Bosch

16

Bier en luiers



10/27/03

ABVI, Kraemer & Van den Bosch

17

Bluff your way into the future

- Question answering
 - wie vond de telefoon uit?
 - waarom is John F. Kennedy vermoord?
- Automatisch samenvatten
- Gepersonaliseerde informatie-filtering

10/27/03

ABVI, Kraemer & Van den Bosch

18

Bluff your way into LT

- Diepst doordrongen: MS Word
 - Maar begin er niet over!
- Spelling- en stijlchecking
- Automatisch vertalen: babelfish (Systran)
- Mens-machine dialoogsystemen
- Verborgen technologie in informatietechnologie (AI included)

10/27/03

ABVI, Kraemer & Van den Bosch

19

Bluff your way into dialogue

- Turing test (1950)
- Eliza (Weizenbaum, 1966)
- Loebner prize (1990s-present)
- maar:
 - doel is converseren, niet begrijpen
 - "echte" dialoog veronderstelt begrip
- Reisinformatie per sprekende computer

10/27/03

ABVI, Kraemer & Van den Bosch

20

Eliza

- P: men are all alike.
- E: in what way?
- P: they are always bugging us about something or other.
- E: can you think of a specific example?
- P: well, my boyfriend made me come here.
- E: go on.
- P: perhaps I could learn to get along with my mother.
- E: tell me more about your family.
- ...

10/27/03

ABVI, Kraemer & Van den Bosch

21

Bluff your way into 2001

- (Kubrick, 1969)
- HAL (=IBM) 9000 wordt opgeleverd op 12 januari 1997
 - bestuurt ruimteschip
 - prettige stem
 - speelt schaak
 - maakt nooit fouten

10/27/03

ABVI, Kraemer & Van den Bosch

22



En na 2001

- Speech-to-speech translation (VERBMOBIL)
- Sprekende helpdesk
- Ambient intelligence
- Communicatieprotocollen huishoudelijke apparaten

10/27/03

ABVI, Kraemer & Van den Bosch

24

