

Textzusammenfassung

07.01.2010

Einführung in die Computerlinguistik

Dominik Fischer

Gliederung

- ▶ 1. Wozu Textzusammenfassung?
- ▶ 2. Herangehensweise bei der Textzusammenfassung
- ▶ 3. statistische Herangehensweisen
- ▶ 4. linguistische Herangehensweisen
- ▶ 5. Probleme der Textzusammenfassung
- ▶ 6. Beispiel und Übung

Wozu Textzusammenfassung?

- ▶ „Informationsflut“ durch Verbreitung des Internets
- ▶ Unmöglich alle relevanten Texte zu einem Thema zu erarbeiten
- ▶ Lösung: automatische Zusammenfassung eines oder mehrerer Texte

Herangehensweise bei der Textzusammenfassung

- ▶ **Aspekte der Textzusammenfassung:**
 - ▶ Extract vs. Abstract (Extract: Sammlung von Sätzen des Originaltextes, Abstract: eigener Text)
 - ▶ Allgemein vs. nutzerorientiert
 - ▶ Informativ vs. Indikativ (Informativ: länger, auch Ergebnisse des Textes, Indikativ: kürzer, keine Ergebnisse)
 - ▶ Zusammenfassung eines vs. Zusammenfassung mehrerer Texte

Herangehensweise bei der Textzusammenfassung

- ▶ **Grundsätzliche Vorgehensweise:**
 - ▶ 1. Identifikation relevanter Textteile
 - ▶ 2. Textstellen in Textteilen isolieren
 - ▶ 3. Zusammenfassung durch Zusammenfügung der Textstellen erstellen
- ▶ **Identifikation der relevanten Textteile durch statistische oder linguistische Methoden**

Statistische Herangehensweisen

- ▶ Gewichtungswerte ermitteln durch:
 - ▶ Schlüsselwort- / Schlüsselphrasen-Methode (Autor gibt wichtige Fakten durch bestimmte Wörter / Phrasen zu erkennen)
 - ▶ Positionsmethode (Sätze in bestimmten Positionen wichtiger bspw. die ersten / letzten Sätze eines Textes, Überschriften)
 - ▶ Worthäufigkeit (häufige Worte abzüglich Stoppworte müssen wichtig sein)
 - ▶ Satzlänge (Lange Sätze wichtiger als kurze)

Statistische Herangehensweise

- ▶ Linguistische Erfordernisse bei den statischen Methoden:
 - ▶ Morphologie: Erkennen von Wortgrenzen und Worten
 - ▶ Lexikographie: Zuordnen von Worten zu Wortliste
 - ▶ Syntax: Erkennen von Satzgrenzen

Linguistische Herangehensweise

- ▶ **Gewichtungswerte ermitteln durch:**
 - ▶ Beziehungen zwischen Sätzen: Sätze die starken Bezug zu (vielen) anderen Sätzen haben sind wichtiger
- ▶ **Linguistische Erfordernisse bei der linguistischen Methode:**
 - ▶ Morphologie: Erkennen von Wortgrenzen und Worten
 - ▶ Lexikographie: Zuordnen von Worten zu Wortliste
 - ▶ Syntax: Erkennen von Satzgrenzen und -strukturen
 - ▶ Semantik: Erkennen von semantischen Beziehungen zwischen Sätzen

Probleme der Textzusammenfassung

- ▶ Isolation von relevanten Textteilen und –stellen:
funktioniert einigermaßen
 - ▶ Probleme mit Ungenauigkeiten bei statistischen Methoden
 - ▶ Probleme mit der Erkennung semantischer und syntaktischer Strukturen bei den linguistischen Methoden

- ▶ Zusammenfassung durch Zusammenfügen relevanter Textstellen erstellen: problematisch
 - ▶ Semantische und syntaktische Probleme bei der Generierung kohärenter Fließtexte
 - ▶ Lösung: Übernahme von kompletten Sätzen des Originaltextes

Beispiel: SweSum

SweSum - Automatic Text Summarizer by [Martin Hassel](#) and [Hercules Dalianis](#)
Localization, Interfaces and Swedish Pronominal Resolution by Martin Hassel

Interface in other languages:



[Lesser options, please!](#)[\[URL\]](#)

Please type or paste a text of your own to summarize:

Alternatively, you can upload a text/HTML file from your own computer:

Keywords that may be important for the text. Choose type of text Choose language of the text

Summary of the original text:

Print keywords and statistics Number of keywords:

Use pronoun resolution (only for Swedish)

Übung

- ▶ Gehen Sie auf die Seite <http://swesum.nada.kth.se/index-eng-adv.html>
- ▶ Kopieren Sie beispielsweise den Text „Mamaia.txt“ in das Textfenster und experimentieren Sie mit den verschiedenen Einstellmöglichkeiten herum.
- ▶ Was fällt Ihnen auf?
- ▶ Welche Ihrer Meinung nach wichtigen Fakten fehlen in den Zusammenfassungen?
- ▶ Gibt es grammatikalische oder logische Probleme in den Zusammenfassungen?

Quellen

- ▶ http://archiv.tu-chemnitz.de/pub/2006/0118/data/Diplomarbeit_Endversion.pdf
- ▶ http://www.cl.uni-heidelberg.de/courses/archiv/ws06/ecl/folien/f_a22.pdf
- ▶ <http://swesum.nada.kth.se/index-eng-adv.html>