

Müssen Texte statistisch anders ausgewertet werden als Menschen?

Stella Neumann

---

# Grundüberlegung I

---

- Empirische Methode am besten für Soziologie und Psychologie (also Humanwissenschaften) entwickelt
  - Über Sprachlehrforschung und Psycholinguistik in die Sprachwissenschaft übernommen, dabei ebenfalls Mensch als Untersuchungsgegenstand
  - In der Korpuslinguistik Texte (= Produkt menschlicher sprachlicher Äußerung) als Untersuchungsgegenstand
- Wie sehr sind die Methoden, die für die Untersuchung von Menschen entwickelt wurden, auf die Untersuchung von Texten übertragbar?
-

# Grundüberlegung II

Unterschiedliche Datengrundlage in Humanwissenschaften und in Korpuslinguistik:

	Humanwissenschaften	Korpuslinguistik
<b>Untersuchungsgegenstand</b>	Menschl. Verhalten	Sprachliche Äußerungen
<b>Grundgesamtheit</b>	z.B. im Telefonbuch verzeichnete Bewohner oder auf dem Campus erreichbare Menschen	z.B. im Verzeichnis Lieferbarer Bücher verzeichnete Bücher oder im Internet abrufbare
<b>Auswahl der Stichprobe aufgrund...</b>	Alter, Bildung, Einkommen, Muttersprache etc.	<del>Texte</del> Textsortenzugehörigkeit, Erscheinungsdatum, Autor, Muttersprache, etc.
<b>Daten</b>	Äußerungen/Einschätzungen von Versuchspersonen	Häufigkeiten in sprachlichen Einheiten, Verhältnismaßzahlen

# Grundgesamtheit

---

- [Humanwissenschaft: im Telefonbuch verzeichnete Bürger]
  - Bücher aus dem Verzeichnis Lieferbarer Bücher
    - Vorteil: gut eingrenzbare, sinnvolle Menge an aktuellen Texten
    - Nachteil: enthält nur Bücher; viele oft gelesene Texte (Gebrauchsanweisungen, Zeitungsartikel, Rechtstexte) sind nicht darin enthalten
  - Im Internet verfügbare Texte
    - Vorteil: große Bandbreite an verfügbaren Texten
    - Nachteil: Ungeklärte Herkunft und Qualität der Texte; mengenmäßige Eingrenzung der Grundgesamtheit → Ziehung einer Zufallsstichprobe nicht möglich
- Wie repräsentativ sind die Texte, die Korpuslinguisten verwenden?
-

# Was ist ein Fall?

---

- [Humanwissenschaften: Mensch]
- Wort? }  
■ Satz? } Gegenstand der Annotation
- Text bzw. Textausschnitt?  Einheit, aus der sich das Korpus zusammensetzt
- Subkorpus (im Vergleich zu anderen Subkorpora)?  Einheit, über die etwas ausgesagt werden soll

→ Was ist nun ein Fall?

---

# Skalenniveau?

Bezeichnung	Erläuterung	Beispiel
Nominalskala	willkürliche Vergabe von Zahlen zur Unterscheidung verschiedener Fälle; die Abstände zwischen den Zahlen sagen nichts aus	Registerzuordnung: Essay = 1, Fiction = 2, etc.
Ordinalskala	Das Objekt mit der größeren Merkmalsausprägung erhält die größere Zahl; Zahlen bilden eine Rangordnung	Schulnoten: 1 ist besser als 2, ist besser als 3..., aber der Abstand zwischen den Noten ist unklar
Intervallskala	Information über Abstände zwischen den Zahlen, aber keinen „echten“ Nullpunkt	Temperatur: Abstand zwischen 0 und 10° Celsius ist genauso groß wie der zwischen 10 und 20°
Verhältnisskala	Der Abstand zwischen den Zahlen ist gleich und es gibt einen sinnvoll interpretierbaren Nullpunkt	Längenmessung: Ein 10 cm langes Brett plus ein 20 cm langes Brett ergibt ein 30 cm langes Brett 😊

Trifft auf Häufigkeitsauswertungen in einem Korpus zu.  
Was aber wenn zwei Register verglichen werden?

# Konsequenzen für korpusbasierte Untersuchungen

---

- Skalenniveau bestimmt Auswahl an Signifikanztests  
Bei Tests für niedrigere Skalenniveaus wie dem Chi<sup>2</sup>-Test gehen sonst nutzbare Informationen verloren
- Wird das in der Korpuslinguistik für jede Untersuchung geklärt?
-

# Unabhängige Gruppen oder wiederholte Messungen?

---

- Unabhängige Gruppen (= between subject)  
Es werden zwei verschiedene Stichproben ausgewertet  
Einsatz unterschiedlicher Lehrmethoden:  
Lerngruppe 1 übt Leseverständnis mit einer traditionellen Methode,  
Gruppe 2 mit einer neuartigen Methode
- Wiederholte Messungen (= within subject)  
Die gleiche Stichprobe wird in verschiedenen Zuständen ausgewertet  
Einfluß von Alkohol auf die Fahrtüchtigkeit:  
Die gleichen Versuchspersonen müssen in nüchternem Zustand und in alkoholisiertem Zustand Verkehrshütchen umfahren

→ Sind Übersetzungen andere Zustände von Originaltexten?

# Schlußfolgerung

---

- Liegt das alles nur daran, dass wir nicht genug über Statistik wissen?
  - Oder brauchen wir für Auswertungen von Texten einen anderen Ansatz?
-