

# ELRC in Deutschland

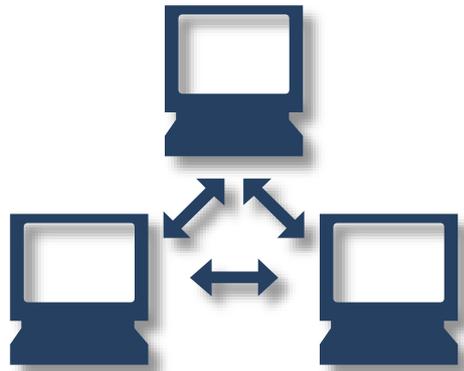
Andreas Witt

Technology  
National Anchor Point

Alexandra Soska

Public Services  
National Anchor Point





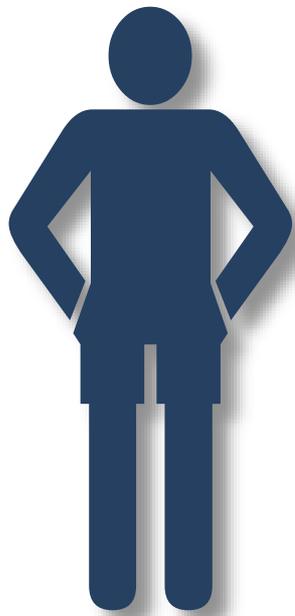
Warum ist es wichtig,  
Sprachdaten auszutauschen?



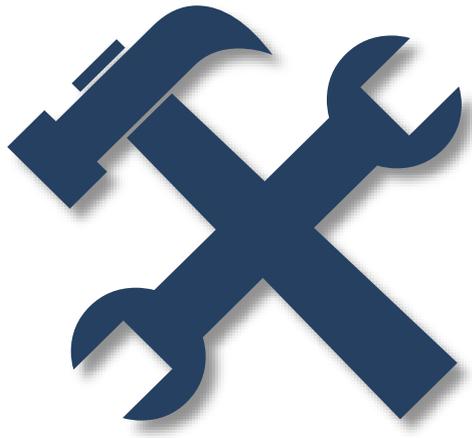
Dürfen wir Daten  
weitergeben?



Wer entscheidet, welche  
Daten weitergegeben  
werden?

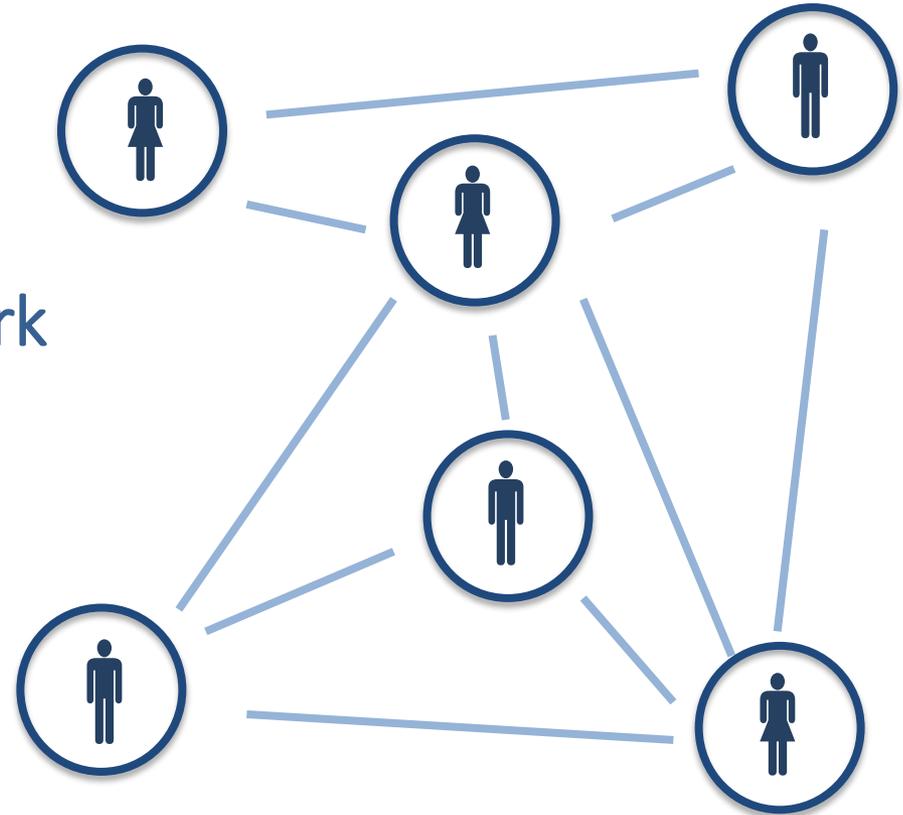


Wer soll das umsetzen?



Was ist technisch zu tun?

Gut organisiertes Netzwerk  
von Sprachendiensten

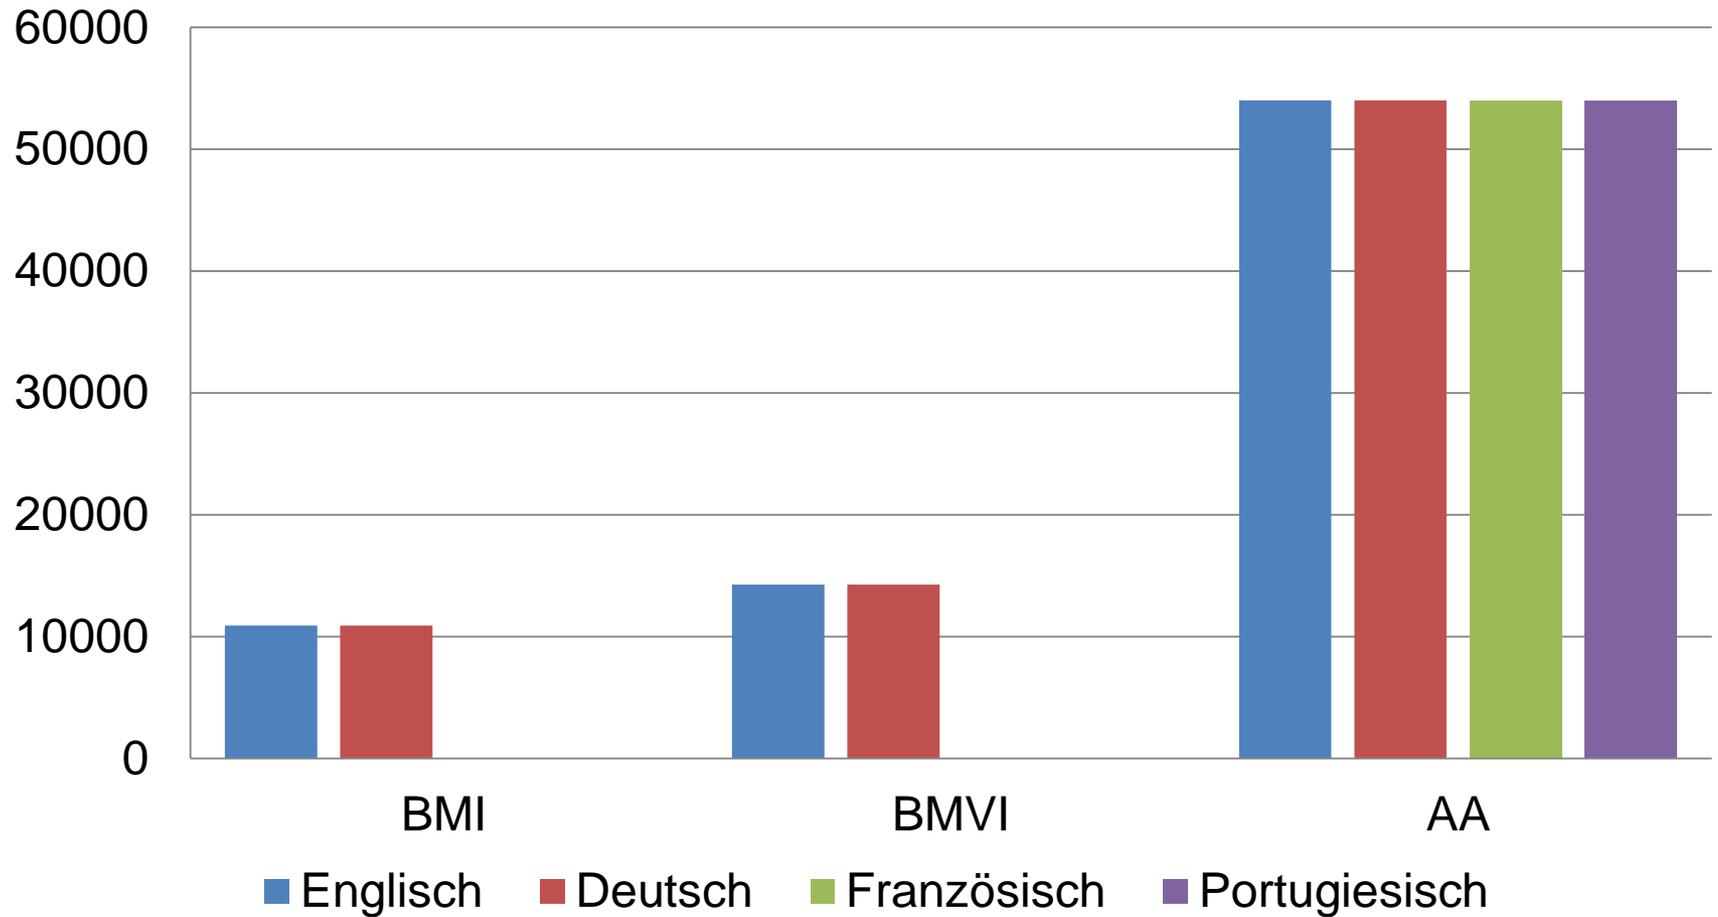


Sprachressourcen leicht  
auffindbar



Gute technische Ausstattung  
& Kenntnisse





## Regelbasierte Ansätze:

- direkte Übersetzung
  - Wort-zu-Wort-Übersetzung mittels Wörterbuch
- Transfer
  - satzbasierte Übersetzung
  - drei Phasen: Analyse, Transfer und Generierung
- Interlingua
  - Analyse und Generierung
  - Interlingua: sprachpaarunabhängig Zwischenrepräsentation
  - keine ideale Repräsentationssprache vorhanden

- beruht auf Informationen aus Textkorpora (zwei- oder auch mehrsprachige Korpora)
- Alignierung: manuelle, automatische oder halbautomatische Auszeichnungen zwischen den Korpora auf Wort-, Phrasen-, Satzebene, etc. zur Verbesserung der Qualität der Übersetzung
- manuelle Alignierung:
  - zuverlässige Ergebnisse, aber nicht effizient bei großen Textmengen
  - Verwendung für Evaluierung oder für statistische Verfahren
- automatische Alignierung:
  - Einteilung in Übersetzungseinheiten
  - Zuordnung durch linguistische oder statistische Algorithmen
  - Effizient, aber fehleranfällig
- halbautomatischen Alignierung:
  - Automatischer Prozess und
  - manuelle Überwachung

- meist werden korpusbasierte Lernverfahren verwendet
- Ebenen: Wörter, Phrasen, ganze Sätze
- Wahrscheinlichkeiten für die Übersetzung eines Terms in einen zielsprachlichen Term werden berechnet
- beeinflusst durch Worthäufigkeit, Position des Wortes im Satz, Satzlänge etc., d.h. nicht durch Wörterbücher oder explizites linguistisches Wissen
- erlerntes Übersetzungsmodell:
  - Übersetzungsmöglichkeiten für ausgangssprachliche Textsequenzen und die
  - dazugehörige Wahrscheinlichkeit
- Sprachmodelle: einsprachigen Korpora
- Übersetzungsvorgang:
  - Decodierung via Übersetzungsmodells (Ermittlung möglicher Übersetzungen)
  - Decodierung via Sprachmodell (Einbeziehung kontextueller Übersetzungsalternativen)

- **Wortbasierte statistische MÜ:**
  - Übersetzungsmodell für Wort-für-Wort-Übersetzungen
  - Annahme, dass die einzelnen Wortübersetzungen unabhängig voneinander existieren
  - Problem: ein Wort kann mehreren Wörtern übersetzt werden und umgekehrt
  - Kontextinformationen werden nicht berücksichtigt
- **Phrasenbasierte statistische MÜ:**
  - Übersetzungsmodell aus Mehrwortsequenzen
  - Neuordnung der Segmente mithilfe eines Sprachmodells
  - Behandlung von Ambiguitäten durch Einbeziehung des Kontextes
- **Neuronale MÜ:**
  - seit wenigen Jahren verfügbar
  - hohe Qualität
  - es sind nicht für alle Sprachpaare zweisprachige Korpora nötig

## Vorteile:

- effizient, da geringe Investitionskosten und hohe Funktionssicherheit
- Verzicht auf Grammatikregeln und Ausnahmen
- schnelle Realisierung und Erweiterung um weitere Sprachen

## Nachteil:

- benötigt großen Mengen der aufbereiteten Textkorpora
- Textmaterial ist domänenspezifisch auszuwählen

## Folgen für ELRC:

- Trainingsdaten aus dem Bereich Behördensprache werden benötigt, denn:
- qualitativ hochwertige mehrsprachige Datensätze werden die maschinelle Übersetzung erheblich verbessern

Fragen?

Danke!



Andreas Witt

E-Mail:

[witt@ids-mannheim.de](mailto:witt@ids-mannheim.de)



Alexandra Soska

E-Mail:

[Alexandra.Soska@bmi.bund.de](mailto:Alexandra.Soska@bmi.bund.de)

Email: [info@lr-coordination.eu](mailto:info@lr-coordination.eu)

Website: [www.lr-coordination.eu](http://www.lr-coordination.eu)



Connecting  
Europe  
Facility