



Seminar für Sprachwissenschaft

# Datenübernahme durch TALAR, das *Tübinger Archive of Language Resources*

## Vorhandene Daten in TALAR

- Gepflegte Referenzdaten
  - Tübinger Baumbank-Collection
  - GermaNet
- Gehostete Daten
  - Daten des SFB 833/SFB 441
  - Daten des GRK 1808
- Daten externer Partner
  - SFB 638
  - Index Thomisticus Treebank
  - ...
- Community Daten
  - Universal Dependency Treebanks (UD)

## Tübingen Archive of Language Resources (TALAR)

<b>Spezialisierung</b>	<ul style="list-style-type: none"> <li>• Baumbanken/Treebanks</li> <li>• Wortnetze</li> <li>• Word-Embeddings</li> </ul>
<b>Modalität</b>	<ul style="list-style-type: none"> <li>• geschrieben</li> <li>• gesprochen</li> </ul>
<b>Akzeptierte Datenformate</b>	<ul style="list-style-type: none"> <li>• GermaNet XML-Format</li> <li>• CoNLL-U</li> <li>• Word-Embeddings</li> <li>• Weitere Formate nach Absprache</li> </ul>
<b>Ansprechperson(en)</b>	<ul style="list-style-type: none"> <li>• Thorsten Trippel</li> <li>• Claus Zinn</li> </ul>

## Suchmöglichkeiten in den gepflegten Daten

The screenshot shows the Synset Search interface. It includes a search bar, a list of results for 'Nachhaltigkeit', and a detailed view of a treebank structure for the sentence 'Daz list daz puoch von den natuerleichen dingen ze daeutsch bracht von maister cunrat von Megenberch'.

## Daten Einbringen

### Voraussetzung:

- Unterstützte Datentypen
  - Qualitätsgesichert
  - Auswahlprozess
- Datenüberlassungsvertrag
  - Muster siehe <https://uni-tuebingen.de/de/134320>
- Offene Lizenz: CC-BY 4.0 oder höher
- Metadaten nach ISO 24622
- Unterstützte Profile
  - *CourseProfile*
  - *ExperimentProfile*
  - *LexicalResourceProfile*
  - *ResourceBundle*

### Initiale Datenübermittlung

- Übermittlung nach BagIT-Standard
- Werkzeugunterstützung: Bagman

The screenshot shows the Bagman interface with buttons for 'Pack your data' and 'Archive HQ'.

# FAIR

## Findable

- Auffindbar mit persistentem Identifikator (PID)
  - Handle / DOI
- Nachweis über Forschungsdatensuchmaschinen
  - z. B. VLO
- Auffindbarkeit über Standardsuchmaschinen

## Accessible

- Downloadmöglichkeit freier Daten
- Zugang zu vorhandenen zugangsbeschränkten Daten
- Metadaten frei zugänglich über technische Protokolle

## Interoperable

- Je nach Datentyp
- Nutzbar in den vorhandenen Auswertungswerkzeugen
- Metadaten: standardkonform und maschinell interpretierbar

## Reusable

- Nutzbar unter den Bedingungen der Lizenzen in eigener Software
- Verwendung in anderen Projektkontexten
- Klare Rechte an den Daten
- Vertrauenswürdige Aufbewahrung

## Zertifizierung des Repositoriums

Zertifikat erteilt am 01. Juni 2023



Aktuell: turnusgemäße Erneuerung



Scott Martens (2013). **TüNDRA**: A Web Application for Treebank Search and Visualization. In: Proceedings of The Twelfth Workshop on Treebanks and Linguistic Theories (TLT12), Sofia, pp. 133–144.

Hinrichs, Marie and Lawrence, Richard and Hinrichs, Erhard (2020): Exploring and Visualizing Wordnet Data with GermaNet **Rover**. In Proceedings of the CLARIN Annual Conference 2020, pp. 32-36.

C. Zinn: **Bagman** - A Tool that Supports Researchers Archiving Their Data. Selected papers from the CLARIN Annual Conference 2021 (Virtual Event), Linköping University Electronic Press, vol. 189, pages 181-189, 2022.