

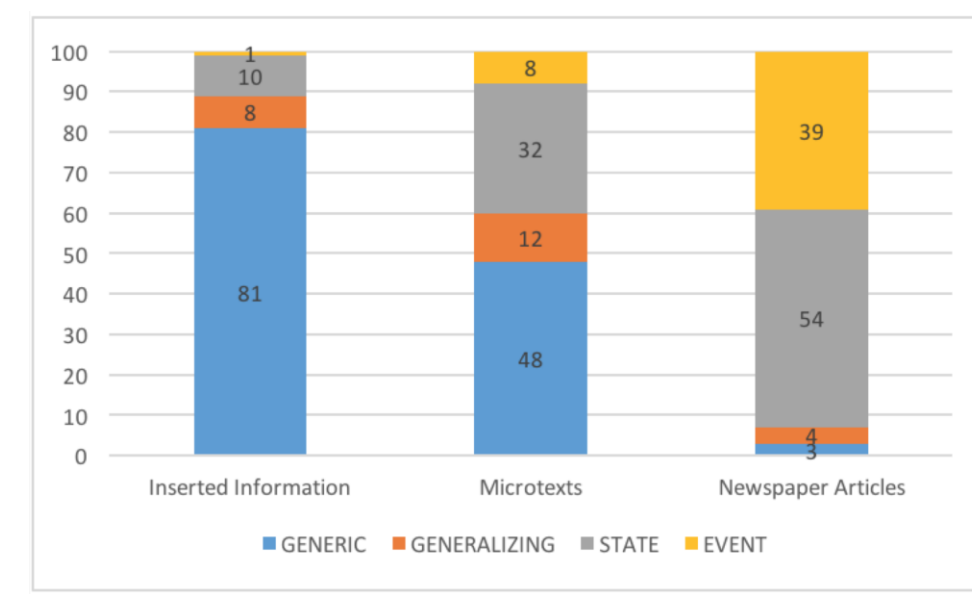
Motivation

Die Rekonstruktion impliziten Wissens in argumentativen Texten

- In **argumentativen Texten** gibt es nur **wenige Verknüpfungen** zwischen Sätzen auf der **Textoberfläche**

(a) Alternative Behandlungen sollten wie herkömmliche Behandlungen subventioniert werden, Behandlungen werden subventioniert, wenn sie zur Vorbeugung, Milderung oder Heilung einer Krankheit führen.
(b) da beide Methoden zur Vorbeugung, Milderung oder Heilung einer Krankheit führen können.

- Fehlende explizite Verbindungen zwischen Sätzen signalisieren implizites Wissen
- Fehlende Informationen werden oft als Generische Sätze kodiert (Becker et al., 2017a)



Forschungslage und Forschungsbeitrag

Automatische Klassifikation von Semantic Clause Types

Forschungslage: Feature-basierte Klassifikatoren (Palmer et al. 2007, Friedrich et al. 2016)

- Anwendung sprachspezifischer und ressourcenintensiver **Features**
- Ergebnisse:** mit Standard-NLP-Features – 69.8 accuracy
mit detaillierten Features (inkl. externer Quellen) – 71.4 accuracy
mit Standard-NLP- & detaillierten Features – 74.7 accuracy

→ **Adaptation** für neue Sprachen ist **aufwendig!**

Unser Ziel: Modellierung eines **Rekurrenten Neuronalen Netzwerks** mit **Attention-Mechanismus** und Informationen über **Kontext & Genre**

- Repräsentation von **Sequenzen**
- Rückgriff auf **Kontext & Genre**
- Fokussierung** auf **Teile** des Inputs
- Übertragbarkeit auf **neue Sprachen**

Datenset

- Englisches Datenset:** Friedrich et al. (2016): Wikipedia (10,607 clauses) und MASC (30,333 clauses), 13 Genres (Email, Aufsatz, Brief, Zeitung, TED Talk, Wikipedia...)
- Deutsches Datensets:** Mavridou et al. (2015) und Becker et al. (2016a,b) + selbst-annotierte Daten (insg. 18,194 clauses), 7 Genres (Fiktion, Kommentar, Bericht...)
- Word Embeddings**
 - Englisch: 300-dim word2vec, trainiert auf Google News (Mikolov et al. 2013)
 - Deutsch: 100-dim word2vec, trainiert auf Webkorpus (Reimers et al., 2014)

Deutsches Datenset:
www.cl.uni-heidelberg.de/english/research/downloads/resource_pages/GER_SET/GER_SE_T_data.shtml

Ergebnisse

		Englisches Testset		Deutsches Testset	
		Accuracy	F1-Score	Accuracy	F1-Score
Lokale Modelle	Lokales Modell (ohne Attention)	66.55	59.14	74.94	67.12
	Lokales Modell+Attention	69.18	68.31	74.51	74.02
	Lokales Modell+Attention+Genre	71.12	69.55	75.56	69.98
Kontextmodelle: Clauses Lokales Modell mit Attention + vorherige Clauses (Tokens, ohne Attention) + Genrelabel	1 vorheriger Clause/Genre	71.67	59.19	74.51	72.41
	2 vorherige Clauses/Genres	71.57	48.12	74.44	72.26
	3 vorherige Clauses/Genres	69.76	42.73	73.35	71.79
	4 vorherige Clauses/Genres	69.29	41.55	73.11	71.12
	5 vorherige Clauses/Genres	68.99	30.78	72.89	70.61
Kontextmodelle: Label Lokales Modell mit Attention + vorherige Label (mit Attention) + Genrelabel	1 vorheriges Label/Genre	69.55	60.21	71.78	52.88
	2 vorherige Label/Genres	71.04	64.54	72.29	52.52
	3 vorherige Label/Genres	71.68	64.42	72.47	52.34
	4 vorherige Label/Genres	71.25	65.06	74.33	51.12
	5 vorherige Label/Genres	72.04	64.74	74.92	50.76
Kontextmodelle: Label + Clauses Lokales Modell (ohne Attention) + vorherige Clauses (Tokens, ohne Attention) + vorherige Label (ohne Attention) + Genrelabel	1 vorheriges Label/Clauses/Genre	71.35	70.82	73.43	59.51
	2 vorherige Label/Clauses/Genres	70.65	68.62	72.23	57.38
	3 vorherige Label/Clauses/Genres	69.90	68.83	71.69	57.99
	4 vorherige Label/Clauses/Genres	69.26	67.47	71.11	56.48
	5 vorherige Label/Clauses/Genres	69.00	64.36	71.09	56.23

Zusammenfassung und weitere Schritte

- Modelle, die **Kontext, Genre** und **Attention-Mechanismus** einbeziehen, erzielen die besten Ergebnisse (vergleichbar mit Performanz featurebasierter Systeme)
- Neuronale Modelle bedürfen keiner Nachbildung von Features für **neue Sprachen**
- Annotationsstudien (Becker et al. 2017a) zeigen außerdem, dass sich ein Großteil der fehlenden Informationen in argumentativen Texten auf **Commonsense Knowledge Relationen** abbilden lässt

Strafen führen zu Verhaltensänderungen. → **Causes (Strafen, Verhaltensänderungen)**

→ Nächster Schritt: Entwicklung eines Commonsense Relation Klassifikators

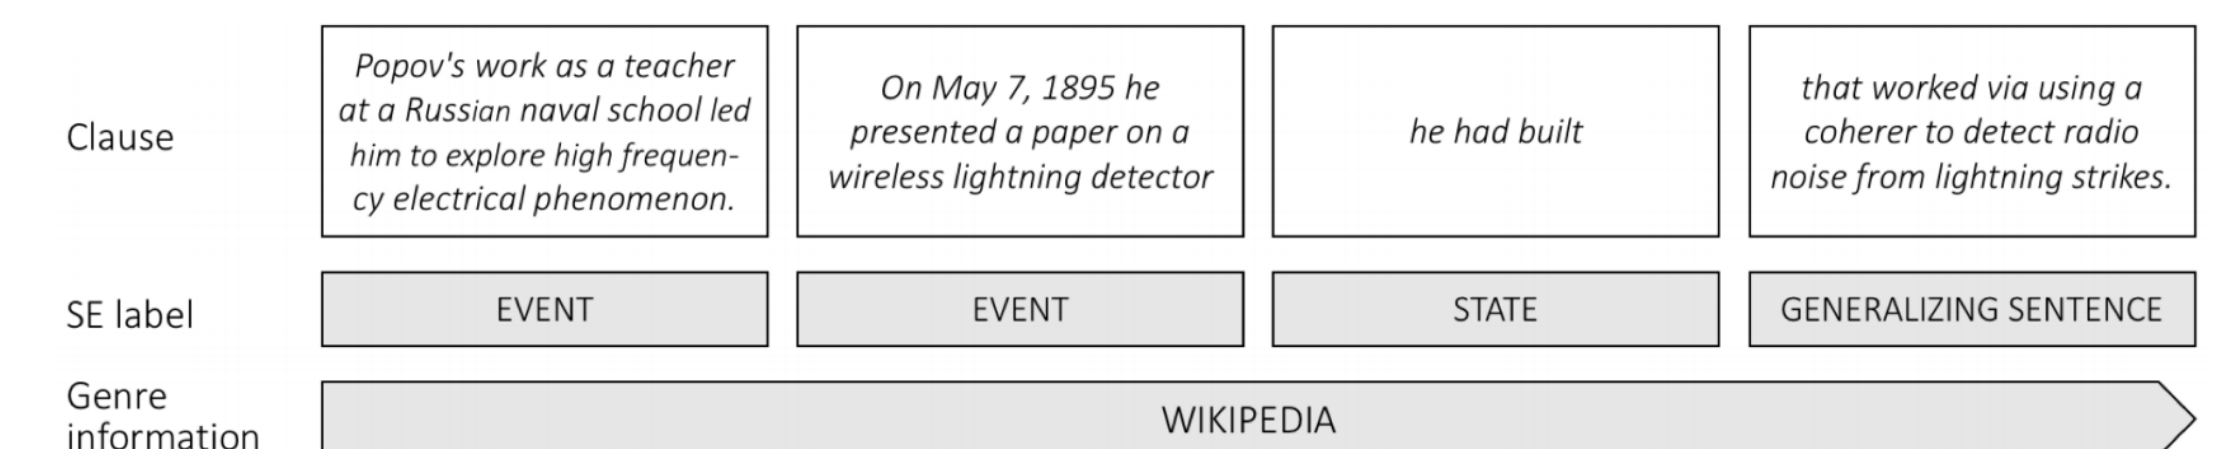
Annotationsinventar

Semantic Clause Types (SCT, Smith 2003, Friedrich et al. 2016) charakterisieren aspektuelle Eigenschaften von Clauses und deren Funktionen im Text/Diskurs:

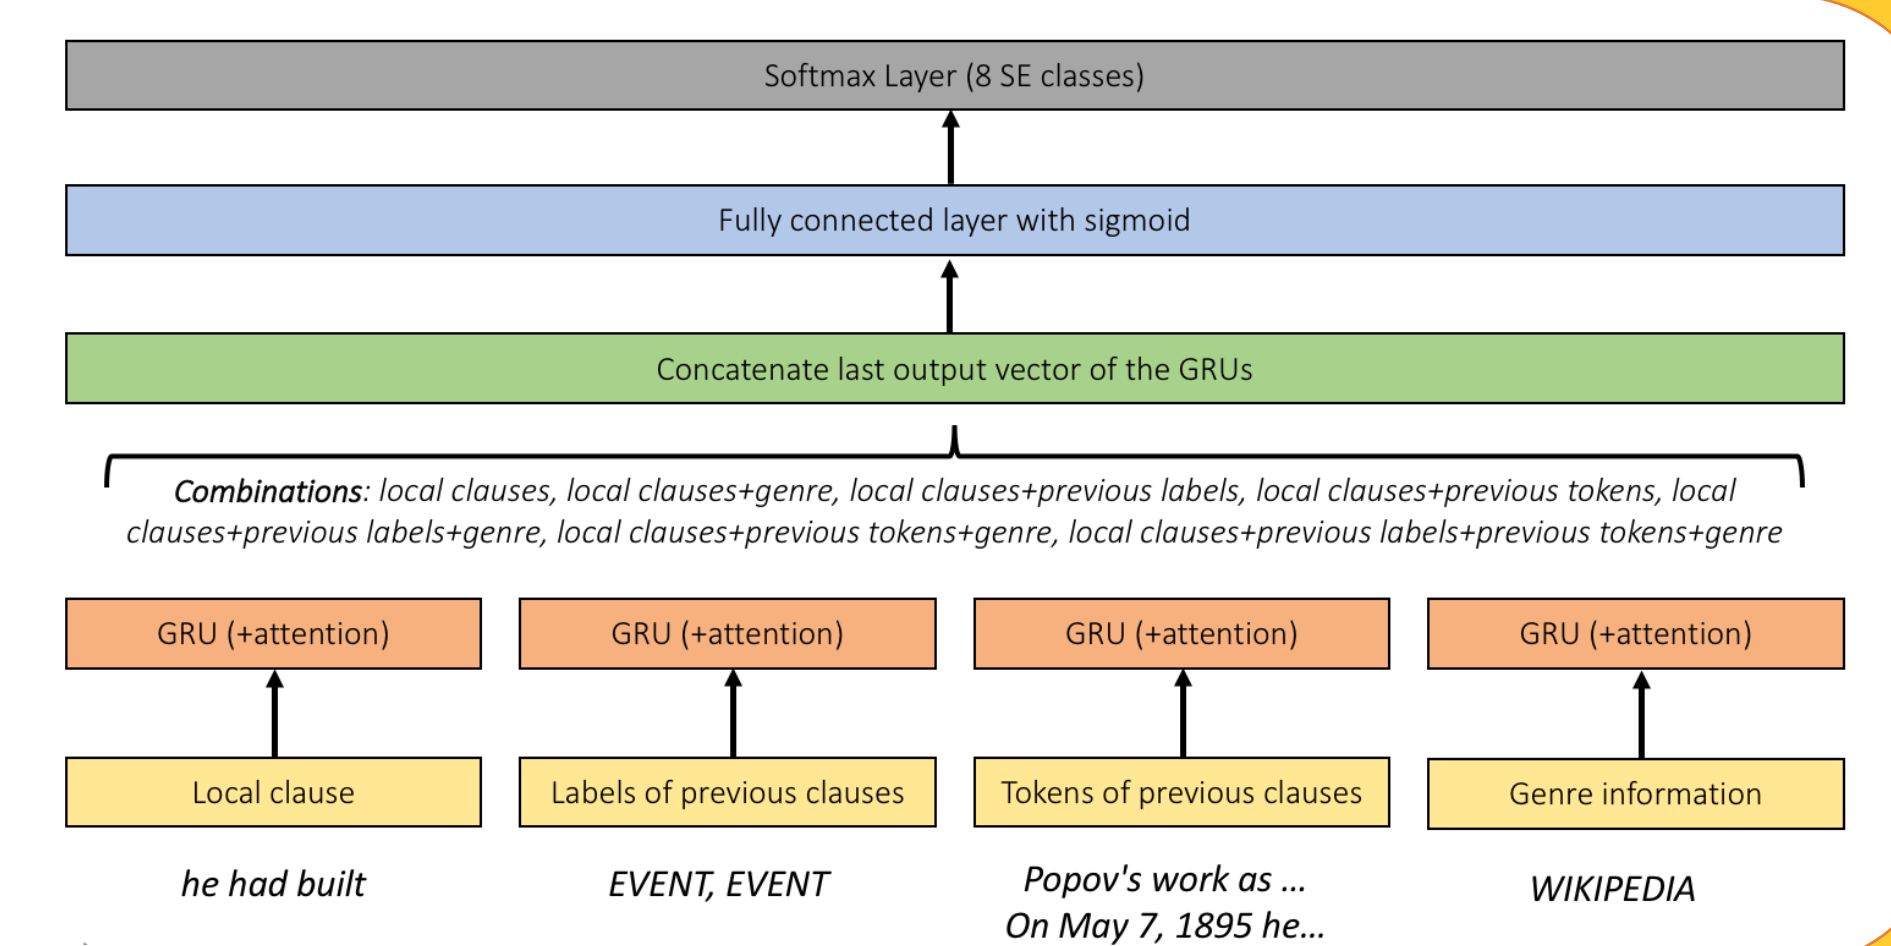
- STATES:** Sven liebt Kuchen.
- EVENTS:** Joe gewann das Spiel.
- GENERALIZING SENTENCES:** Marlene füttert oft meine Katze.
- GENERIC SENTENCES:** Wale sind Säugetiere.
- REPORT:** Lena sagt, dass sie kommen wird.
- QUESTION:** Warum gehst du schon?
- IMPERATIVE:** Hör dir das an!

Modell

Modellierung von Kontext- und Genreinformationen




Architektur des Neuronalen Modells




Analysen

Position von Wörtern mit hohen Attentionwerten



Attentionwerte pro POS Tags

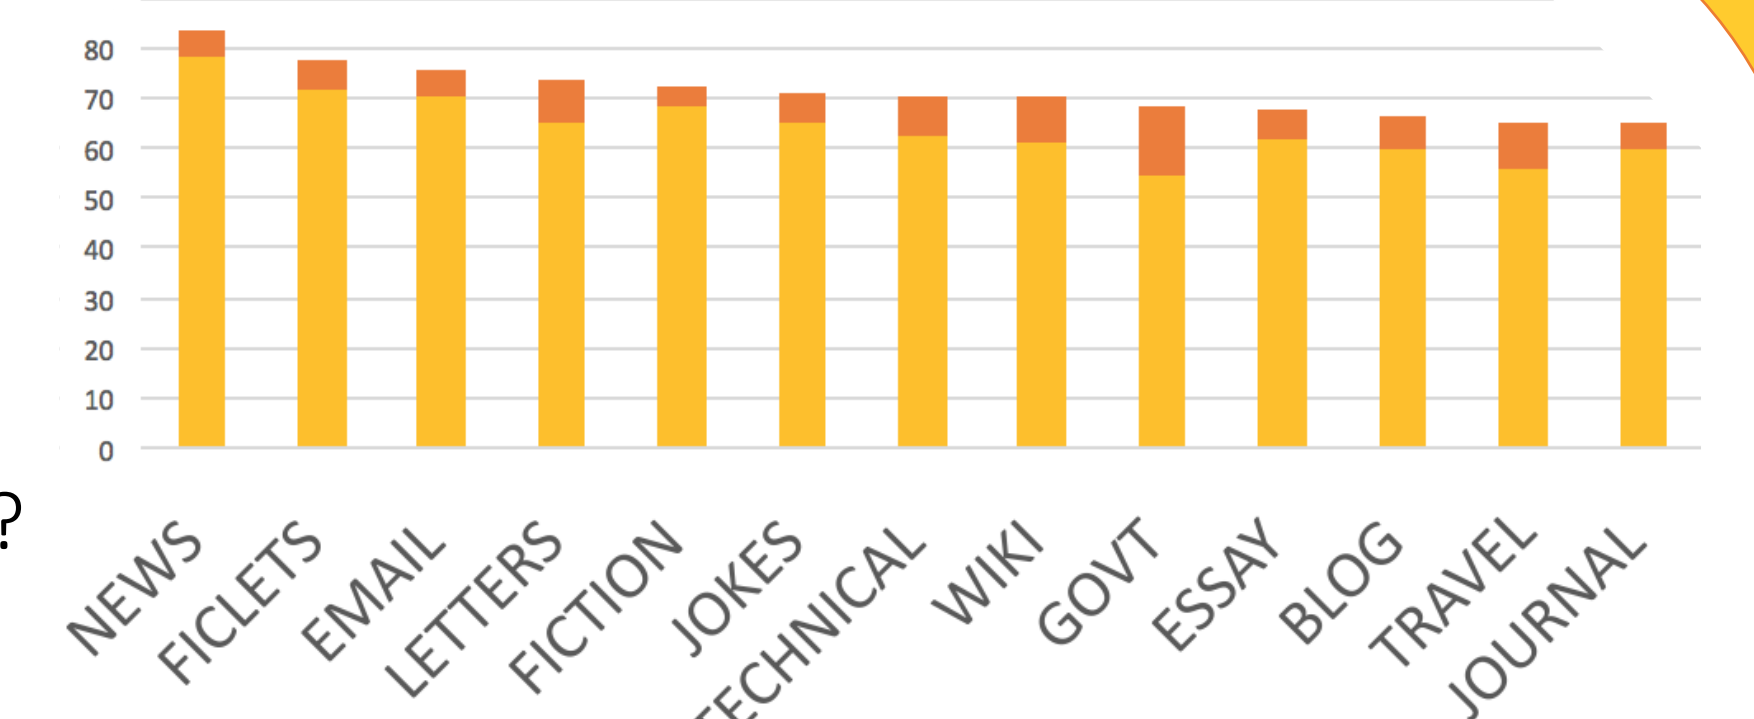


Wörter mit hohen Attentionwerten

- STATE:** Nomen, Pronomen, pred. Hilfsverben (*editors, I, am*)
- EVENT:** Gerundien (*thinking, writing*)
- GENERIC:** Adjektive, Adverbien, Modalverben, unbest. Artikel (*awake, can, an*)
- GENERALIZING:** Named Entities (*York, States*)

Einfluss von Genres

- Welche Genres sind einfacher zu klassifizieren?
- Welche Genres haben bei der Klassifikation geholfen?



Ähnlichkeit von Genres

- (Sequences von) SCT unterscheiden sich je nach Genre: häufigste N-Gramme pro Genre:
 - GENERIC → arg. Texte,
 - EVENTS → Berichte
 - STATE-STATE → Journale, GENERIC-GENERIC → Wikipedia
 - EVENT-EVENT-EVENT → Witze, EVENT-STATE-STATE → Parlamentsdebatten
- Verteilung von SCT und deren N-Grammen → symmetrische Kullback-Leibler-Divergenz

