

Zwischen Interpretation und Berechnung

Didaktische Exploration computerlinguistischer
Verfahren
mit augmentierten Transkripten von
Verkaufsgesprächen

Paul Koop

Lehr- und Lernmaterial 2026

Zusammenfassung

Dieses Lehr- und Lernmaterial dient der didaktischen Exploration computerlinguistischer Verfahren auf der Grundlage der acht Transkripte von Verkaufsgesprächen. Im Unterschied zu den vorangegangenen ARS-Versionen 2.0 und 3.0, die auf interpretativ gebildeten Terminalzeichen basierten, wird hier der Schritt in Richtung automatischer Sprachverarbeitung vollzogen. Die Verfahren werden zu Demonstrationszwecken auf augmentierten Daten trainiert, um ihre Funktionsweise transparent zu machen. Der Fokus liegt auf dem didaktischen Erkenntnisgewinn, nicht auf empirischer Validität. Die Szenarien C (Computerlinguistische Integration) und D (Hybride Modellierung) werden schrittweise entwickelt und miteinander verglichen.

Inhaltsverzeichnis

1	Einleitung: Didaktische Ziele und methodologische Reflexion	2
2	Die acht Transkripte: Rohdaten und Terminalzeichen	3
2.1	Die Rohdaten	3
2.1.1	Transkript 1 - Metzgerei	3
2.1.2	Transkript 2 - Marktplatz (Kirschen)	3
2.1.3	Transkript 3 - Fischstand	4
2.1.4	Transkript 4 - Gemüsestand (ausführlich)	4
2.1.5	Transkript 5 - Gemüsestand (mit KAV zu Beginn)	4
2.1.6	Transkript 6 - Käseverkaufsstand	4
2.1.7	Transkript 7 - Bonbonstand	5
2.1.8	Transkript 8 - Bäckerei	5
2.2	Die Terminalzeichenketten (ARS 3.0)	6
3	Szenario C: Computerlinguistische Integration	7
3.1	Didaktische Augmentierung	7
3.2	Speech Act Recognition mit Transformer-Modellen	8
3.3	Word Embeddings und semantische Ähnlichkeit	12
3.4	Topic Modeling mit BERTopic	15
3.5	Rhetorical Structure Theory (RST)	19
3.6	Integration der Komponenten in Szenario C	24
4	Szenario D: Hybride Modellierung	29
4.1	CRF für sequenzielle Abhängigkeiten	29
4.2	Transformer-Embeddings als Ergänzung	33
4.3	Graph Neural Networks für die Nonterminal-Hierarchie	36
4.4	Attention-Mechanismen für relevante Vorgänger	40
4.5	Integration der Komponenten in Szenario D	44
5	Vergleich der Szenarien und methodologische Reflexion	48
5.1	Gegenüberstellung der Ansätze	48
5.2	Didaktische Erkenntnisse aus Szenario C	49
5.3	Didaktische Erkenntnisse aus Szenario D	49
5.4	Fazit für die Lehrpraxis	50
6	Ausblick	50

1 Einleitung: Didaktische Ziele und methodologische Reflexion

Die vorangegangenen Versionen der Algorithmisch Rekursiven Sequenzanalyse (ARS 2.0 und 3.0) haben gezeigt, wie aus interpretativ gewonnenen Terminalzeichenketten formale Grammatiken induziert werden können. Diese Verfahren bleiben methodologisch kontrolliert: Die Kategorienbildung erfolgt durch qualitative Interpretation, die formalen Modelle explizieren lediglich die beobachtbaren Regularitäten.

Die nun folgenden Szenarien C und D wagen einen Schritt über diese methodologische Grenze hinaus. Sie explorieren, wie computerlinguistische Verfahren – insbesondere neuronale Netze, Word Embeddings und Topic Models – auf die acht Transkripte angewendet werden könnten, wenn man sie zu Demonstrationszwecken augmentiert.

Dieses Dokument ist als Lehr- und Lernmaterial konzipiert. Es verfolgt folgende didaktische Ziele:

1. **Verständnis neuronaler Architekturen:** Wie funktionieren Transformer, LSTM-Netze und Attention-Mechanismen auf Sequenzdaten?
2. **Data Augmentation als Technik:** Wie kann man mit kleinen Datensätzen umgehen, um die Funktionsweise von Verfahren zu demonstrieren?
3. **Vergleich verschiedener Modellierungsebenen:** Welche Unterschiede bestehen zwischen rein computerlinguistischen (C) und hybriden (D) Ansätzen?
4. **Methodologische Reflexion:** Wo liegen die Grenzen automatischer Verfahren im Vergleich zur interpretativen Kategorienbildung?

Alle hier vorgestellten Implementierungen arbeiten mit augmentierten Daten – die acht Originaltranskripte wurden künstlich vervielfacht, um das Training neuronaler Netze zu ermöglichen. Die Ergebnisse sind daher nicht empirisch valide, sondern dienen ausschließlich der didaktischen Veranschaulichung.

2 Die acht Transkripte: Rohdaten und Terminalzeichen

2.1 Die Rohdaten

Die folgenden acht Transkripte dokumentieren Verkaufsgespräche auf dem Aachener Marktplatz im Juni/Juli 1994. Sie bilden die empirische Grundlage aller folgenden Analysen.

2.1.1 Transkript 1 - Metzgerei

Datum: 28. Juni 1994, **Ort:** Metzgerei, Aachen, 11:00 Uhr

```
1 Kunde: Guten Tag!
2 Verk uferin: Guten Tag!
3 Kunde: Einmal von der groben Leberwurst, bitte.
4 Verk uferin: Wie viel darf's denn sein?
5 Kunde: Zwei hundert Gramm.
6 Verk uferin: Sonst noch etwas?
7 Kunde: Ja, dann noch ein St ck von dem Schwarzw lder Schinken.
8 Verk uferin: Wie gro soll das St ck sein?
9 Kunde: So um die dreihundert Gramm.
10 Verk uferin: Das macht dann acht Mark zwanzig.
11 Kunde: Bitte.
12 Verk uferin: Danke und einen sch nen Tag noch!
13 Kunde: Danke, ebenfalls!
```

Listing 1: Transkript 1 - Rohdaten

2.1.2 Transkript 2 - Marktplatz (Kirschen)

Datum: 28. Juni 1994, **Ort:** Marktplatz, Aachen

```
1 Verk ufer: Kirschen kann jeder probieren hier!
2 Kunde 1: Ein halbes Kilo Kirschen, bitte.
3 Verk ufer: Ein halbes Kilo? Oder ein Kilo?
4 Verk ufer: Drei Mark, bitte.
5 Kunde 1: Danke sch n!
6 Verk ufer: Kirschen kann jeder probieren hier!
7 Kunde 2: Ein halbes Kilo, bitte.
8 Verk ufer: Drei Mark, bitte.
9 Kunde 2: Danke sch n!
```

Listing 2: Transkript 2 - Rohdaten

2.1.3 Transkript 3 - Fischstand

Datum: 28. Juni 1994, **Ort:** Fischstand, Marktplatz, Aachen

```
1 Kunde: Ein Pfund Seelachs, bitte.  
2 Verk ufer: Seelachs, alles klar.  
3 Verk ufer: Vier Mark neunzehn, bitte.  
4 Kunde: Danke sch n!
```

Listing 3: Transkript 3 - Rohdaten

2.1.4 Transkript 4 - Gemüsestand (ausführlich)

Datum: 28. Juni 1994, **Ort:** Gemüsestand, Aachen, Marktplatz, 11:00 Uhr

```
1 Kunde: H ren Sie, ich nehme ein paar Champignons mit.  
2 Verk ufer: Braune oder helle?  
3 Kunde: Nehmen wir die hellen.  
4 Verk ufer: Die sind beide frisch, keine Sorge.  
5 Kunde: Wie ist es mit Pfifferlingen?  
6 Verk ufer: Ah, die sind super!  
7 Kunde: Kann ich die in Reissalat tun?  
8 Verk ufer: Eher kurz anbraten in der Pfanne.  
9 Kunde: Okay, mache ich.  
10 Verk ufer: Sch nen Tag noch!  
11 Kunde: Gleichfalls!
```

Listing 4: Transkript 4 - Rohdaten

2.1.5 Transkript 5 - Gemüsestand (mit KAV zu Beginn)

Datum: 26. Juni 1994, **Ort:** Gemüsestand, Aachen, Marktplatz, 11:00 Uhr

```
1 Kunde 1: Auf Wiedersehen!  
2 Kunde 2: Ich h tte gern ein Kilo von den Granny Smith pfeln hier  
.  
3 Verk ufer: Sonst noch etwas?  
4 Kunde 2: Ja, noch ein Kilo Zwiebeln.  
5 Verk ufer: Sechs Mark f nfundzwanzig, bitte.  
6 Kunde 2: Auf Wiedersehen!
```

Listing 5: Transkript 5 - Rohdaten

2.1.6 Transkript 6 - Käseverkaufsstand

Datum: 28. Juni 1994, **Ort:** Käseverkaufsstand, Aachen, Marktplatz

```

1 Kunde 1: Guten Morgen!
2 Verk ufer: Guten Morgen!
3 Kunde 1: Ich h tte gerne f nfhundert Gramm holl ndischen Gouda.
4 Verk ufer: Am St ck?
5 Kunde 1: Ja, am St ck , bitte.

```

Listing 6: Transkript 6 - Rohdaten

2.1.7 Transkript 7 - Bonbonstand

Datum: 28. Juni 1994, **Ort:** Bonbonstand, Aachen, Marktplatz, 11:30 Uhr

```

1 Kunde: Von den gemischten h tte ich gerne hundert Gramm.
2 Verk ufer: F r zu Hause oder zum Mitnehmen?
3 Kunde: Zum Mitnehmen, bitte.
4 Verk ufer: F nfzig Pfennig, bitte.
5 Kunde: Danke!

```

Listing 7: Transkript 7 - Rohdaten

2.1.8 Transkript 8 - Bäckerei

Datum: 9. Juli 1994, **Ort:** Bäckerei, Aachen, 12:00 Uhr

```

1 (Schritte h rbar , Hintergrundger usche , teilweise unverst ndlich
   )
2 Kunde: Guten Tag!
3 (Unverst ndliche Begr ung im Hintergrund)
4 Verk uferin: Einmal unser bester Kaffee, frisch gemahlen, bitte.
5 (Ger usche der Kaffeem hle , Verpackungsger usche)
6 Verk uferin: Sonst noch etwas?
7 Kunde: Ja, noch zwei St ck Obstsalat und ein Sch lchen Sahne.
8 Verk uferin: In Ordnung!
9 (Ger usche der Kaffeem hle , Papierger usche)
10 Verk uferin: Ein kleines Sch lchen Sahne, ja?
11 Kunde: Ja, danke.
12 (T rger usch , Lachen, Papierger usche)
13 Verk uferin: Keiner k mmert sich darum, die T ren zu len .
14 Kunde: Ja, das ist immer so.
15 (Lachen, Ger usche von M nzen und Verpackung)
16 Verk uferin: Das macht vierzehn Mark und neunzehn Pfennig, bitte.
17 Kunde: Ich zahle in Kleingeld.
18 (Lachen und Ger usche von M nzen)
19 Verk uferin: Vielen Dank, sch nen Sonntag noch!
20 Kunde: Danke, Ihnen auch!

```

2.2 Die Terminalzeichenketten (ARS 3.0)

Für die ARS 3.0 wurden diese Rohdaten in Terminalzeichenketten überführt, die als Grundlage für die hierarchische Grammatikinduktion dienten:

Tabelle 1: Terminalzeichenketten der acht Transkripte

Transkript	Terminalzeichenkette
1 (Metzgerei)	KBG, VBG, KBBd, VBBd, KBA, VBA, KBBd, VBBd, KBA, VAA, KAA, VAV
2 (Kirschen)	VBG, KBBd, VBBd, VAA, KAA, VBG, KBBd, VAA, KAA
3 (Fischstand)	KBBd, VBBd, VAA, KAA
4 (Gemüse)	KBBd, VBBd, KBA, VBA, KBBd, VBA, KAE, VAE, KAA, VAV, KAV
5 (Gemüse KAV)	KAV, KBBd, VBBd, KBBd, VAA, KAV
6 (Käse)	KBG, VBG, KBBd, VBBd, KAA
7 (Bonbon)	KBBd, VBBd, KBA, VAA, KAA
8 (Bäckerei)	KBG, VBBd, KBBd, VBA, VAA, KAA, VAV, KAV

Die Bedeutung der Terminalzeichen:

- **KBG**: Kunden-Gruß
- **VBG**: Verkäufer-Gruß
- **KBBd**: Kunden-Bedarf (konkret)
- **VBBd**: Verkäufer-Nachfrage
- **KBA**: Kunden-Antwort
- **VBA**: Verkäufer-Reaktion
- **KAE**: Kunden-Erkundigung
- **VAE**: Verkäufer-Auskunft
- **KAA**: Kunden-Abschluss
- **VAA**: Verkäufer-Abschluss
- **KAV**: Kunden-Verabschiedung
- **VAV**: Verkäufer-Verabschiedung

3 Szenario C: Computerlinguistische Integration

Szenario C realisiert eine vollständig computerlinguistische Modellierung der acht Transkripte. Es umfasst vier Komponenten:

1. **Speech Act Recognition:** Automatische Erkennung der Sprechakte aus den Rohdaten
2. **Word Embeddings:** Vektorielle Repräsentation der Äußerungen
3. **Topic Modeling:** Identifikation thematischer Verschiebungen
4. **Rhetorical Structure Theory (RST):** Analyse der argumentativen Struktur

3.1 Didaktische Augmentierung

Da neuronale Netze für ihr Training große Datenmengen benötigen, werden die acht Transkripte zu Demonstrationszwecken augmentiert:

```
1 def augment_transcripts_for_teaching(transcripts, factor=20):
2     """
3     Augmentiert die acht Transkripte f r didaktische Zwecke.
4
5     Didaktischer Hinweis: Diese Augmentierung dient
6     ausschlie ßlich der
7     Veranschaulichung der Methodik. Die resultierenden Daten
8     sind nicht
9     empirisch valide, sondern erm glichen lediglich die
10    Demonstration
11    der Funktionsweise neuronaler Verfahren.
12    """
13    augmented = []
14
15    # 1. Basis-Augmentierung: einfaches Kopieren
16    for _ in range(factor):
17        augmented.extend(transcripts)
18
19    # 2. Syntaktische Variationen (didaktisch kontrolliert)
20    import copy
21    import random
22
23    for transcript in transcripts:
```

```

21     for _ in range(factor // 4):
22         var = copy.deepcopy(transcript)
23         # Vertausche zwei benachbarte uerungen (
                selten)
24         if len(var) > 3 and random.random() < 0.1:
25             idx = random.randint(0, len(var)-2)
26             var[idx], var[idx+1] = var[idx+1], var[idx]
27         augmented.append(var)
28
29     # 3. Lexikalische Variationen (Synonyme)
30     synonyms = {
31         'Guten Tag': ['Guten Morgen', 'Hallo', 'Guten Abend'
                ],
32         'Danke': ['Vielen Dank', 'Danke sch n', 'Merci'],
33         'Bitte': ['Bitte sehr', 'Gern geschehen']
34     }
35
36     # Hier k nnten weitere Variationen implementiert werden
37
38     return augmented

```

Listing 9: Data Augmentation für Lehrzwecke

3.2 Speech Act Recognition mit Transformer-Modellen

Die automatische Erkennung der Sprechakte erfolgt mit einem feinabgestimmten BERT-Modell:

```

1  """
2  Speech Act Recognition mit transformer-basierten Modellen
3  Didaktische Implementierung f r Lehrzwecke
4  """
5
6  import torch
7  import torch.nn as nn
8  from transformers import BertTokenizer, BertModel
9  import numpy as np
10 from sklearn.preprocessing import LabelEncoder
11 from torch.utils.data import Dataset, DataLoader
12
13 class SpeechActDataset(Dataset):

```

```

14     """Dataset f r Speech Act Recognition"""
15     def __init__(self, utterances, labels, tokenizer,
16                 max_length=128):
17         self.utterances = utterances
18         self.labels = labels
19         self.tokenizer = tokenizer
20         self.max_length = max_length
21
22     def __len__(self):
23         return len(self.utterances)
24
25     def __getitem__(self, idx):
26         utterance = self.utterances[idx]
27         label = self.labels[idx]
28
29         encoding = self.tokenizer(
30             utterance,
31             truncation=True,
32             padding='max_length',
33             max_length=self.max_length,
34             return_tensors='pt'
35         )
36
37         return {
38             'input_ids': encoding['input_ids'].flatten(),
39             'attention_mask': encoding['attention_mask'].
40                 flatten(),
41             'label': torch.tensor(label, dtype=torch.long)
42         }
43
44 class BertSpeechActClassifier(nn.Module):
45     """
46     BERT-basierter Klassifikator f r Sprechakte
47     Didaktisch vereinfachte Architektur
48     """
49     def __init__(self, num_classes=12, dropout=0.3):
50         super().__init__()
51         self.bert = BertModel.from_pretrained('bert-base-
52             german-cased')
53         self.dropout = nn.Dropout(dropout)

```

```

51     self.classifier = nn.Linear(768, num_classes)
52
53     # Freeze BERT layers f r didaktische Zwecke (
54         schnelleres Training)
55     for param in self.bert.parameters():
56         param.requires_grad = False
57
58     def forward(self, input_ids, attention_mask):
59         outputs = self.bert(input_ids=input_ids,
60                             attention_mask=attention_mask)
61         pooled_output = outputs.pooler_output
62         dropped = self.dropout(pooled_output)
63         logits = self.classifier(dropped)
64         return logits
65
66 def prepare_speech_act_data(transcripts, terminal_chains):
67     """
68     Bereitet die Daten f r das Speech Act Training vor
69     """
70
71     utterances = []
72     labels = []
73
74     # Extrahiere alle u erungen aus den Rohdaten
75     # Hier vereinfacht: Mapping der Terminalzeichen auf
76     # Sprechakte
77     for trans, chain in zip(transcripts, terminal_chains):
78         # In einer vollst ndigen Implementierung m ssten
79         # die Rohdaten geparkt werden
80         # F r didaktische Zwecke verwenden wir die
81         # Terminalzeichen direkt
82         for symbol in chain:
83             utterances.append(f"Beispiel u erung f r {
84                 symbol}")
85             labels.append(symbol)
86
87     # Label-Encoding
88     label_encoder = LabelEncoder()
89     y_encoded = label_encoder.fit_transform(labels)
90
91     return utterances, y_encoded, label_encoder

```

```

85
86 def train_speech_act_model(utterances, labels, epochs=10):
87     """
88     Trainiert das Speech Act Recognition Modell
89     """
90     tokenizer = BertTokenizer.from_pretrained('bert-base-
        german-cased')
91     dataset = SpeechActDataset(utterances, labels, tokenizer)
92     dataloader = DataLoader(dataset, batch_size=8, shuffle=
        True)
93
94     model = BertSpeechActClassifier(num_classes=len(set(
        labels)))
95     optimizer = torch.optim.Adam(model.parameters(), lr=2e-5)
96     criterion = nn.CrossEntropyLoss()
97
98     print("\n=== Speech Act Recognition Training (didaktisch)
        ===")
99     for epoch in range(epochs):
100         total_loss = 0
101         for batch in dataloader:
102             optimizer.zero_grad()
103             outputs = model(batch['input_ids'], batch['
                attention_mask'])
104             loss = criterion(outputs, batch['label'])
105             loss.backward()
106             optimizer.step()
107             total_loss += loss.item()
108
109             print(f"Epoch {epoch+1}: Loss = {total_loss/len(
                dataloader):.4f}")
110
111         return model, tokenizer, label_encoder
112
113 # Didaktischer Hinweis
114 print("\n" + "="*70)
115 print("DIDAKTISCHER HINWEIS ZUR SPEECH ACT RECOGNITION")
116 print("="*70)
117 print("Die hier gezeigte Implementierung verwendet
    augmentierte")

```

```

118 print("Daten und dient ausschlie ß lich Lehrzwecken. Die
      automatische")
119 print("Erkennung von Sprechakten w rde in der Praxis:")
120 print("      Millionen von annotierten Trainingsdaten
      ben tigen")
121 print("      Auf spezifische Dom nen (Verkaufsgespr che)
      feinabgestimmt werden")
122 print("      Mit erheblichen Unsicherheiten behaftet sein")

```

Listing 10: Speech Act Recognition mit BERT

3.3 Word Embeddings und semantische Ähnlichkeit

Für die Quantifizierung semantischer Ähnlichkeit werden vortrainierte Word Embeddings verwendet:

```

1  """
2  Word Embeddings f r semantische  hnlichkeitsanalysen
3  Didaktische Implementierung mit vortrainierten Modellen
4  """
5
6  from sentence_transformers import SentenceTransformer
7  import numpy as np
8  from sklearn.metrics.pairwise import cosine_similarity
9  import matplotlib.pyplot as plt
10 import seaborn as sns
11
12 class SemanticAnalyzer:
13     """
14     Analysiert semantische  hnlichkeiten zwischen
15     uerungen
16     """
17     def __init__(self, model_name='paraphrase-multilingual-
18     MiniLM-L12-v2'):
19         print(f"Lade vortrainiertes Modell: {model_name}")
20         self.model = SentenceTransformer(model_name)
21         self.embeddings = {}
22
23     def encode utterances(self, utterances):
24         """
25         Erzeugt Embeddings f r eine Liste von uerungen

```

```

24     """
25     embeddings = self.model.encode(utterances)
26     for utt, emb in zip(utterances, embeddings):
27         self.embeddings[utt] = emb
28     return embeddings
29
30 def similarity_matrix(self, utterances):
31     """
32     Berechnet die hnlichkeitsmatrix f r alle
33         uerungen
34     """
35     embeddings = self.encode_utterances(utterances)
36     sim_matrix = cosine_similarity(embeddings)
37     return sim_matrix
38
39 def find_similar(self, query, utterances, top_k=5):
40     """
41     Findet die hnlichsten uerungen zu einer Query
42     """
43     query_emb = self.model.encode([query])[0]
44     utt_embs = self.encode_utterances(utterances)
45
46     similarities = cosine_similarity([query_emb],
47                                     utt_embs)[0]
48     top_indices = np.argsort(similarities)[-top_k:][::-1]
49
50     results = []
51     for idx in top_indices:
52         results.append({
53             'utterance': utterances[idx],
54             'similarity': similarities[idx]
55         })
56
57     return results
58
59 def visualize_similarity(self, utterances, labels=None):
60     """
61     Visualisiert die hnlichkeitsmatrix als Heatmap
62     """
63     sim_matrix = self.similarity_matrix(utterances)

```

```

62
63     plt.figure(figsize=(12, 10))
64     sns.heatmap(sim_matrix,
65                 xticklabels=labels if labels else range(
66                     len(utterances)),
67                 yticklabels=labels if labels else range(
68                     len(utterances)),
69                 cmap='viridis', vmin=0, vmax=1)
70     plt.title('Semantische hnlichkeit zwischen
71               uerungen ')
72     plt.tight_layout()
73     plt.savefig('semantic_similarity.png', dpi=150)
74     plt.show()
75
76 # Didaktisches Beispiel
77 def demonstrate_semantic_analysis():
78     """
79     Demonstriert die semantische Analyse an Beispielen
80     """
81     analyzer = SemanticAnalyzer()
82
83     # Beispiel- uerungen aus den Transkripten
84     utterances = [
85         "Guten Tag!",
86         "Guten Morgen!",
87         "Einmal Leberwurst, bitte.",
88         "Ich h tte gerne Wurst.",
89         "Danke sch n!",
90         "Vielen Dank!",
91         "Auf Wiedersehen!",
92         "Tsch ss!"
93     ]
94
95     print("\n=== Semantische hnlichkeitsanalyse ===")
96
97     # hnlichkeitsmatrix berechnen
98     sim_matrix = analyzer.similarity_matrix(utterances)
99
100    # hnlichste uerungen f r "Guten Tag!"
101    similar = analyzer.find_similar("Guten Tag!", utterances,

```



```

        top_k=3)
99     print("\n hnlichste zu 'Guten Tag!':")
100     for r in similar:
101         print(f"    {r['utterance']}: {r['similarity']:.3f}")
102
103     # Visualisierung
104     analyzer.visualize_similarity(utterances, utterances)
105
106     return analyzer
107
108 # Didaktischer Hinweis
109 print("\n" + "="*70)
110 print("DIDAKTISCHER HINWEIS ZU WORD EMBEDDINGS")
111 print("="*70)
112 print("Die verwendeten Embeddings wurden auf gro en Korpora"
113       )
114 print("(Wikipedia, Nachrichten, Webtexte) vortrainiert. Sie")
115 print("erfassen allgemeinsprachliche hnlichkeiten , nicht
       die")
print("spezifischen Kategorien der Verkaufsgespr che.")

```

Listing 11: Semantische Ähnlichkeit mit Word Embeddings

3.4 Topic Modeling mit BERTopic

Für die Identifikation thematischer Verschiebungen wird BERTopic verwendet:

```

1  """
2  Topic Modeling zur Identifikation thematischer Verschiebungen
3  Didaktische Implementierung mit BERTopic
4  """
5
6  from bertopic import BERTopic
7  from sklearn.feature_extraction.text import CountVectorizer
8  import pandas as pd
9  import matplotlib.pyplot as plt
10
11 class TranscriptTopicModeler:
12     """
13     F hrt Topic Modeling auf den Transkripten durch
14     """

```

```

15     def __init__(self):
16         self.model = None
17         self.topics = None
18         self.probs = None
19
20     def prepare_documents(self, transcripts):
21         """
22         Bereitet die Transkripte als Dokumente f r Topic
23             Modeling vor
24         """
25         documents = []
26         metadata = []
27
28         for i, transcript in enumerate(transcripts, 1):
29             # Jedes Transkript als ein Dokument
30             doc = ' '.join(transcript)
31             documents.append(doc)
32             metadata.append(f'Transkript {i}')
33
34             # Alternativ: Jede uerung als Dokument
35             # for j, utterance in enumerate(transcript):
36             #     documents.append(utterance)
37             #     metadata.append(f'T{i}_U{j}')
38
39         return documents, metadata
40
41     def fit_model(self, documents):
42         """
43         Trainiert das Topic Model
44         """
45         # Benutzerdefinierte Stopw rter
46         stopwords = ['bitte', 'danke', 'gern', 'mal', 'noch',
47                     'ja', 'nein']
48         vectorizer = CountVectorizer(stop_words=stopwords)
49
50         self.model = BERTopic(
51             embedding_model="paraphrase-multilingual-MiniLM-
                    L12-v2",
                    vectorizer_model=vectorizer,
                    verbose=True,

```

```

52         nr_topics='auto'
53     )
54
55     self.topics, self.probs = self.model.fit_transform(
56         documents)
57     return self.topics, self.probs
58
59 def visualize_topics(self):
60     """
61     Visualisiert die gefundenen Themen
62     """
63     if self.model is None:
64         return
65
66     fig = self.model.visualize_topics()
67     fig.write_html("topic_visualization.html")
68
69     # Statistik
70     topic_counts = pd.Series(self.topics).value_counts()
71     print("\n=== Themenverteilung ===")
72     for topic, count in topic_counts.items():
73         if topic == -1:
74             print(f"Outlier: {count} Dokumente")
75         else:
76             words = self.model.get_topic(topic)[:5]
77             words_str = ', '.join([w for w, _ in words])
78             print(f"Thema {topic}: {count} Dokumente - {
79                 words_str}")
80
81 def visualize_topics_over_time(self, documents,
82     timestamps):
83     """
84     Visualisiert Themenentwicklung über die Zeit
85     """
86     if self.model is None:
87         return
88
89     topics_over_time = self.model.topics_over_time(
90         documents,
91         timestamps,

```

```

89         nr_bins=8
90     )
91
92     fig = self.model.visualize_topics_over_time(
93         topics_over_time)
94     fig.write_html("topics_over_time.html")
95
96 def demonstrate_topic_modeling(transcripts):
97     """
98     Demonstriert Topic Modeling an den Transkripten
99     """
100     modeler = TranscriptTopicModeler()
101     documents, metadata = modeler.prepare_documents(
102         transcripts)
103
104     print("\n=== Topic Modeling der acht Transkripte ===")
105     topics, probs = modeler.fit_model(documents)
106
107     for i, (doc, topic, prob, meta) in enumerate(zip(
108         documents, topics, probs, metadata)):
109         if topic != -1:
110             words = modeler.model.get_topic(topic)[:3]
111             words_str = ', '.join([w for w, _ in words])
112             print(f"{meta}: Thema {topic} (Confidence: {prob
113                 :.2f}) - {words_str}")
114         else:
115             print(f"{meta}: Kein klares Thema (Outlier)")
116
117     modeler.visualize_topics()
118     return modeler
119
120 # Didaktischer Hinweis
121 print("\n" + "="*70)
122 print("DIDAKTISCHER HINWEIS ZUM TOPIC MODELING")
123 print("="*70)
124 print("Topic Modeling identifiziert latente Themen in
125     Textkorpora.")
126 print("Bei nur acht Dokumenten ist die Themenfindung instabil
127     .")
128 print("Die Ergebnisse dienen daher nur der Veranschaulichung

```

```

    der")
123 print("Methodik, nicht der inhaltlichen Analyse.")

```

Listing 12: Topic Modeling mit BERTopic

3.5 Rhetorical Structure Theory (RST)

Für die Analyse der argumentativen Struktur wird ein RST-Parser implementiert:

```

1  """
2  Rhetorical Structure Theory (RST) Analyse
3  Didaktische Implementierung f r Sequenzdaten
4  """
5
6  import networkx as nx
7  import matplotlib.pyplot as plt
8  from collections import defaultdict
9
10 class RSTRelation:
11     """Repr sentiert eine RST-Relation zwischen
12     Textsegmenten"""
13     def __init__(self, type_name, nucleus, satellite,
14         direction='nucleus-satellite'):
15         self.type = type_name # z.B. 'Elaboration', '
16             Contrast', 'Cause'
17         self.nucleus = nucleus # Zentrales Segment
18         self.satellite = satellite # Unterst tzendes
19             Segment
20         self.direction = direction
21
22 class SimpleRSTParser:
23     """
24     Einfacher RST-Parser f r didaktische Zwecke
25     Basierend auf cue phrases und strukturellen Mustern
26     """
27
28     # Cue Phrases f r verschiedene Relationen
29     cue_phrases = {
30         'Elaboration': ['zum Beispiel', 'insbesondere', '
31             n mlich', 'genauer'],

```

```

27         'Contrast': ['aber', 'jedoch', 'hingegen', 'dagegen'
28             ],
29         'Cause': ['weil', 'da', 'denn', 'deshalb', 'daher'],
30         'Condition': ['wenn', 'falls', 'sofern'],
31         'Purpose': ['um zu', 'damit'],
32         'Sequence': ['dann', 'danach', 'zuerst', '
33             schlie ßlich']
34     }
35
36     def __init__(self):
37         self.relations = []
38         self.graph = nx.DiGraph()
39
40     def segment_transcript(self, transcript):
41         """
42         Segmentiert ein Transkript in elementare
43         Diskurseinheiten (EDUs)
44         Vereinfacht: Jede uerung ist eine EDU
45         """
46         return transcript
47
48     def identify_relations(self, segments):
49         """
50         Identifiziert RST-Relationen zwischen Segmenten
51         Didaktisch vereinfachte Implementierung
52         """
53         relations = []
54
55         for i in range(len(segments)-1):
56             current = segments[i]
57             next_seg = segments[i+1]
58
59             # Pr üfe auf Cue Phrases
60             for rel_type, cues in self.cue_phrases.items():
61                 for cue in cues:
62                     if cue in current.lower() or cue in
63                         next_seg.lower():
64                         relations.append(RSTRelation(
65                             type_name=rel_type,
66                             nucleus=i,

```

```

63         satellite=i+1
64     ))
65     break
66
67     # Standard: Sequenz-Relation
68     if i < len(segments)-1:
69         relations.append(RSTRelation(
70             type_name='Sequence',
71             nucleus=i,
72             satellite=i+1
73         ))
74
75     return relations
76
77 def build_tree(self, segments, relations):
78     """
79     Baut einen RST-Baum aus den identifizierten
80     Relationen
81     """
82     self.graph.clear()
83
84     # Knoten hinzuf gen
85     for i, seg in enumerate(segments):
86         self.graph.add_node(i, text=seg[:30] + '...' if
87             len(seg) > 30 else seg)
88
89     # Kanten hinzuf gen
90     for rel in relations:
91         self.graph.add_edge(rel.nucleus, rel.satellite,
92             relation=rel.type)
93
94     return self.graph
95
96 def parse(self, transcript):
97     """
98     Vollst ndige RST-Analyse eines Transkripts
99     """
100     segments = self.segment_transcript(transcript)
101     relations = self.identify_relations(segments)
102     tree = self.build_tree(segments, relations)

```

```

101
102     return {
103         'segments': segments,
104         'relations': relations,
105         'tree': tree
106     }
107
108 def visualize(self, title="RST-Struktur"):
109     """
110     Visualisiert den RST-Baum
111     """
112     pos = nx.spring_layout(self.graph)
113     plt.figure(figsize=(12, 8))
114
115     # Knoten zeichnen
116     nx.draw_networkx_nodes(self.graph, pos, node_color='
117         lightblue',
118                             node_size=500)
119
120     # Kanten zeichnen mit Relationstyp als Label
121     for edge in self.graph.edges(data=True):
122         nx.draw_networkx_edges(self.graph, pos, [(edge
123             [0], edge[1])])
124         nx.draw_networkx_edge_labels(
125             self.graph, pos,
126             {(edge[0], edge[1]): edge[2]['relation']}
127         )
128
129     # Knotenlabels
130     labels = {node: f"{node}: {self.graph.nodes[node]['
131         text'}"]}
132     for node in self.graph.nodes():
133         nx.draw_networkx_labels(self.graph, pos, labels,
134                                 font_size=8)
135
136     plt.title(title)
137     plt.axis('off')
138     plt.tight_layout()
139     plt.savefig('rst_structure.png', dpi=150)
140     plt.show()

```



```

137
138 def demonstrate_rst_analysis(transcripts):
139     """
140     Demonstriert RST-Analyse an den Transkripten
141     """
142     parser = SimpleRSTParser()
143
144     print("\n=== RST-Analyse der Transkripte ===")
145
146     for i, transcript in enumerate(transcripts, 1):
147         print(f"\nTranskript {i}:")
148         result = parser.parse(transcript)
149
150         # Zeige identifizierte Relationen
151         for rel in result['relations'][:5]: # Nur erste 5
152             seg1 = result['segments'][rel.nucleus][:20] + '
153                 ...'
154             seg2 = result['segments'][rel.satellite][:20] + '
155                 ...'
156             print(f"    {rel.type}: {seg1}      {seg2}")
157
158         if i == 1: # Nur erstes Transkript visualisieren
159             parser.visualize(f"RST-Struktur Transkript {i}")
160
161     return parser
162
163 # Didaktischer Hinweis
164 print("\n" + "="*70)
165 print("DIDAKTISCHER HINWEIS ZUR RST-ANALYSE")
166 print("="*70)
167 print("Die hier implementierte RST-Analyse ist stark
168     vereinfacht.")
169 print("Ein vollständiger RST-Parser würde:")
170 print("    Aufwendige manuelle Annotation erfordern")
171 print("    Mit trainierten neuronalen Modellen arbeiten")
172 print("    Mehrere Hierarchieebenen von Diskursrelationen
173     berücksichtigen")

```

Listing 13: Rhetorical Structure Theory Parser

3.6 Integration der Komponenten in Szenario C

Die vollständige Integration aller Komponenten in Szenario C:

```
1  """
2  Szenario C: Vollständige computerlinguistische Integration
3  Didaktische Implementierung für Lehrzwecke
4  """
5
6  import os
7  import json
8  from datetime import datetime
9
10 class ScenarioC:
11     """
12     Integriert alle computerlinguistischen Komponenten:
13     - Speech Act Recognition
14     - Word Embeddings / Semantische Analyse
15     - Topic Modeling
16     - RST-Analyse
17     """
18
19     def __init__(self, transcripts, terminal_chains):
20         self.transcripts = transcripts
21         self.terminal_chains = terminal_chains
22         self.results = {}
23
24         print("\n" + "="*70)
25         print("SZENARIO C: COMPUTERLINGUISTISCHE INTEGRATION"
26               )
27         print("="*70)
28         print("\nDieses Szenario demonstriert die Anwendung")
29         print("computerlinguistischer Verfahren auf die acht"
30               )
31         print("Transkripte. Alle Ergebnisse dienen"
32               )
33         print("didaktischen")
34         print("Zwecken und sind nicht empirisch valide.\n")
35
36     def run_speech_act_recognition(self):
37         """
38         Führt die Speech Act Recognition aus
39         """
```

```

35     """
36     print("\n--- Speech Act Recognition ---")
37     utterances, labels, encoder = prepare_speech_act_data
38         (
39             self.transcripts, self.terminal_chains
40         )
41
42     model, tokenizer, label_encoder =
43         train_speech_act_model(
44             utterances, labels, epochs=5
45         )
46
47     self.results['speech_act'] = {
48         'model': model,
49         'tokenizer': tokenizer,
50         'label_encoder': label_encoder,
51         'num_classes': len(label_encoder.classes_)
52     }
53
54     return self.results['speech_act']
55
56 def run_semantic_analysis(self):
57     """
58     Führt die semantische Ähnlichkeitsanalyse aus
59     """
60     print("\n--- Semantische Ähnlichkeitsanalyse ---")
61     analyzer = SemanticAnalyzer()
62
63     # Sammle alle Äußerungen
64     all_utterances = []
65     for transcript in self.transcripts:
66         all_utterances.extend(transcript)
67
68     # Ähnlichkeitsmatrix
69     sim_matrix = analyzer.similarity_matrix(
70         all_utterances[:20]) # Nur erste 20
71
72     self.results['semantic'] = {
73         'analyzer': analyzer,
74         'utterances': all_utterances,

```

```

72         'similarity_matrix': sim_matrix
73     }
74
75     return self.results['semantic']
76
77 def run_topic_modeling(self):
78     """
79     F hrt das Topic Modeling aus
80     """
81     print("\n--- Topic Modeling ---")
82     modeler = TranscriptTopicModeler()
83     documents, metadata = modeler.prepare_documents(self.
84         transcripts)
85     topics, probs = modeler.fit_model(documents)
86     modeler.visualize_topics()
87
88     self.results['topic'] = {
89         'modeler': modeler,
90         'topics': topics,
91         'probabilities': probs,
92         'documents': documents,
93         'metadata': metadata
94     }
95
96     return self.results['topic']
97
98 def run_rst_analysis(self):
99     """
100     F hrt die RST-Analyse aus
101     """
102     print("\n--- RST-Analyse ---")
103     parser = SimpleRSTParser()
104
105     rst_results = []
106     for i, transcript in enumerate(self.transcripts, 1):
107         result = parser.parse(transcript)
108         rst_results.append({
109             'transcript_id': i,
110             'segments': result['segments'],
111             'relations': [(r.type, r.nucleus, r.satellite

```

```

111         ) for r in result['relations']]
112     })
113
114     if i == 1:
115         parser.visualize(f"RTS-Struktur Transkript {i}")
116
117     self.results['rst'] = rst_results
118     return rst_results
119
120 def run_all(self):
121     """
122     F hrt alle Analysen aus
123     """
124     self.run_speech_act_recognition()
125     self.run_semantic_analysis()
126     self.run_topic_modeling()
127     self.run_rst_analysis()
128
129     # Zusammenfassung
130     print("\n" + "="*70)
131     print("ZUSAMMENFASSUNG SZENARIO C")
132     print("="*70)
133     print(f"    Speech Act Recognition: {self.results['speech_act']['num_classes']} Klassen")
134     print(f"    Semantische Analyse: {len(self.results['semantic']['utterances'])} uerungen ")
135     print(f"    Topic Modeling: {len(set(self.results['topic']['topics']))} Themen")
136     print(f"    RST-Analyse: {len(self.results['rst'])} Transkripte analysiert")
137
138     return self.results
139
140 # Didaktische Ausf hrung
141 def run_scenario_c_demonstration():
142     """
143     F hrt die vollst ndige Demonstration von Szenario C aus
144     """
145     # Lade die Transkripte

```

```

145 from ars_data import transcripts, terminal_chains
146
147 # Augmentiere die Daten f r didaktische Zwecke
148 augmented_transcripts = augment_transcripts_for_teaching(
149     transcripts, factor=10)
150 augmented_chains = augment_transcripts_for_teaching(
151     terminal_chains, factor=10)
152
153 print("\n" + "="*70)
154 print("DIDAKTISCHE AUGMENTIERUNG")
155 print("="*70)
156 print(f"Original: {len(transcripts)} Transkripte")
157 print(f"Augmentiert: {len(augmented_transcripts)}
158     Transkripte")
159
160 # F hre Szenario C aus
161 scenario = ScenarioC(augmented_transcripts,
162     augmented_chains)
163 results = scenario.run_all()
164
165 # Speichere Ergebnisse
166 with open('scenario_c_results.json', 'w') as f:
167     # Konvertiere nicht-serialisierbare Objekte
168     serializable = {
169         'speech_act': {'num_classes': results['speech_act']
170             ['num_classes']},
171         'semantic': {'num_utterances': len(results['
172             semantic']['utterances'])},
173         'topic': {'num_topics': len(set(results['topic']
174             ['topics']))},
175         'rst': results['rst']
176     }
177     json.dump(serializable, f, indent=2)
178
179 print("\nErgebnisse gespeichert in 'scenario_c_results.
180     json'")
181
182 return results
183
184 if __name__ == "__main__":

```

```
177 run_scenario_c_demonstration()
```

Listing 14: Szenario C - Vollständige Integration

4 Szenario D: Hybride Modellierung

Szenario D integriert computerlinguistische Verfahren mit den interpretativ gebildeten Kategorien der ARS 3.0. Es überspringt die vollständige Automatisierung der Kategorienbildung (Szenario C) und nutzt die neuen Verfahren komplementär.

4.1 CRF für sequenzielle Abhängigkeiten

Conditional Random Fields modellieren Abhängigkeiten der Sprechakte vom weiteren Kontext:

```
1  """
2  Conditional Random Fields (CRF) f r sequenzielle
   Abh ngigkeiten
3  Didaktische Implementierung mit sklearn-crfsuite
4  """
5
6  import sklearn_crfsuite
7  from sklearn_crfsuite import metrics
8  import numpy as np
9
10 class CRFSequenceModel:
11     """
12     CRF-Modell f r die Sequenzmodellierung der
       Terminalzeichen
13     """
14
15     def __init__(self):
16         self.crf = sklearn_crfsuite.CRF(
17             algorithm='lbfgs',
18             c1=0.1,  # L1-Regularisierung
19             c2=0.1,  # L2-Regularisierung
20             max_iterations=100,
21             all_possible_transitions=True
22         )
23         self.label_encoder = None
```

```

24
25 def word2features(self, tokens, i):
26     """
27     Erzeugt Features f r Position i in der Sequenz
28     """
29     word = tokens[i]
30
31     features = {
32         'bias': 1.0,
33         'word': word,
34         'word.is_first': i == 0,
35         'word.is_last': i == len(tokens) - 1,
36         'word.prefix_K': word.startswith('K'),
37         'word.prefix_V': word.startswith('V'),
38         'word.suffix_A': word.endswith('A'),
39         'word.suffix_B': word.endswith('B'),
40         'word.suffix_E': word.endswith('E'),
41         'word.suffix_G': word.endswith('G'),
42         'word.suffix_V': word.endswith('V'),
43     }
44
45     # Kontext-Features
46     if i > 0:
47         word_prev = tokens[i-1]
48         features.update({
49             '-1:word': word_prev,
50             '-1:word.prefix_K': word_prev.startswith('K')
51             ,
52             '-1:word.prefix_V': word_prev.startswith('V')
53             ,
54             '-1:word.suffix_A': word_prev.endswith('A'),
55         })
56     else:
57         features['BOS'] = True
58
59     if i < len(tokens) - 1:
60         word_next = tokens[i+1]
61         features.update({
62             '+1:word': word_next,
63             '+1:word.prefix_K': word_next.startswith('K')

```



```

        ,
        '+1:word.prefix_V': word_next.startswith('V')
        ,
        '+1:word.suffix_A': word_next.endswith('A'),
    })
else:
    features['EOS'] = True

    return features

def extract_features(self, sequences):
    """
    Extrahiert Features f r alle Sequenzen
    """
    X = []
    for seq in sequences:
        X.append([self.word2features(seq, i) for i in
                    range(len(seq))])
    return X

def fit(self, sequences, labels):
    """
    Trainiert das CRF-Modell
    """
    X = self.extract_features(sequences)
    self.crf.fit(X, labels)
    return self

def predict(self, sequences):
    """
    Sagt Labels f r neue Sequenzen vorher
    """
    X = self.extract_features(sequences)
    return self.crf.predict(X)

def evaluate(self, test_sequences, test_labels):
    """
    Evaluiert das Modell
    """
    pred = self.predict(test_sequences)

```

```

99
100     # Flatten f r Metriken
101     y_true = [label for seq in test_labels for label in
102               seq]
103
104     y_pred = [label for seq in pred for label in seq]
105
106     return {
107         'accuracy': np.mean(np.array(y_true) == np.array(
108             y_pred)),
109         'classification_report': metrics.
110             flat_classification_report(
111                 test_labels, pred, labels=sorted(set(y_true))
112             )
113     }
114
115 def demonstrate_crf(terminal_chains):
116     """
117     Demonstriert CRF-Modellierung auf den Terminalzeichen
118     """
119     print("\n=== CRF-Modellierung der Terminalzeichen ===")
120
121     # Train-Test-Split (didaktisch)
122     train_size = int(len(terminal_chains) * 0.7)
123     train_chains = terminal_chains[:train_size]
124     test_chains = terminal_chains[train_size:]
125
126     # Features extrahieren
127     model = CRFSequenceModel()
128     X_train = model.extract_features(train_chains)
129
130     # Training
131     print(f"Trainiere CRF mit {len(train_chains)} Sequenzen
132           ...")
133     model.fit(train_chains, train_chains) # Labels sind die
134                                           Sequenzen selbst
135
136     # Evaluation
137     results = model.evaluate(test_chains, test_chains)
138     print(f"\nGenauigkeit: {results['accuracy']:.3f}")

```

```
134     return model
```

Listing 15: CRF für sequenzielle Abhängigkeiten

4.2 Transformer-Embeddings als Ergänzung

Transformer-Embeddings werden zusätzlich zu den kategorialen Terminalzeichen verwendet:

```
1  """
2  Transformer-Embeddings als Ergänzung zu kategorialen
3  Terminalzeichen
4  """
5  import torch
6  import numpy as np
7  from sentence_transformers import SentenceTransformer
8
9  class TerminalEmbeddingEnricher:
10     """
11     Ergänzt Terminalzeichen um semantische Embeddings der
12     zugrundeliegenden Unerungen
13     """
14     def __init__(self, model_name='paraphrase-multilingual-
15     MiniLM-L12-v2'):
16         self.model = SentenceTransformer(model_name)
17         self.symbol_to_embedding = {}
18         self.symbol_to_text = self._create_symbol_mapping()
19
20     def _create_symbol_mapping(self):
21         """
22         Erstellt eine Mapping von Terminalzeichen zu
23         Beispieltexen
24         """
25         return {
26             'KBG': ['Guten Tag', 'Guten Morgen', 'Hallo'],
27             'VBG': ['Guten Tag', 'Guten Morgen', 'Hallo
28                     zur ck'],
29             'KBBd': ['Einmal Leberwurst', 'Ich h tte gerne
30                     K se', 'Ein Kilo pfel bitte'],
```

```

27         'VBBd': ['Wie viel darf es sein?', 'Welche Sorte?
28                 ', 'Sonst noch etwas?'],
29         'KBA': ['Zweihundert Gramm', 'Die hellen bitte',
30                 'Ja, gerne'],
31         'VBA': ['In Ordnung', 'Kommt sofort', 'Alles klar
32                 '],
33         'KAE': ['Kann ich das in Salat tun?', 'Woher
34                 kommen die?', 'Ist das frisch?'],
35         'VAE': ['Eher anbraten', 'Aus der Region', 'Ja,
36                 ganz frisch'],
37         'KAA': ['Bitte', 'Danke', 'Ja, danke'],
38         'VAA': ['Das macht 8 Mark 20', '3 Mark bitte', '
39                 14 Mark 19'],
40         'KAV': ['Auf Wiedersehen', 'Tsch ss', 'Einen
41                 sch nen Tag'],
42         'VAV': ['Vielen Dank', 'Sch nen Tag noch', 'Auf
43                 Wiedersehen']
44     }
45
46     def get_embedding(self, symbol):
47         """
48         Gibt das Embedding f r ein Terminalzeichen zur ck
49         """
50         if symbol in self.symbol_to_embedding:
51             return self.symbol_to_embedding[symbol]
52
53         # Durchschnitt der Beispieltext-Embeddings
54         texts = self.symbol_to_text.get(symbol, [symbol])
55         embeddings = self.model.encode(texts)
56         avg_embedding = np.mean(embeddings, axis=0)
57
58         self.symbol_to_embedding[symbol] = avg_embedding
59         return avg_embedding
60
61     def enrich_sequence(self, sequence):
62         """
63         Erweitert eine Sequenz von Terminalzeichen um
64         Embeddings
65         """
66         symbols = sequence

```

```

58         embeddings = np.array([self.get_embedding(sym) for
59                                 sym in symbols])
60
61     return {
62         'symbols': symbols,
63         'embeddings': embeddings,
64         'combined': np.column_stack([
65             self._one_hot_encode(symbols),
66             embeddings
67         ]) if len(symbols) > 0 else np.array([])
68     }
69
70 def _one_hot_encode(self, symbols):
71     """
72     One-Hot-Encoding der Terminalzeichen
73     """
74     unique_symbols = sorted(set(self.symbol_to_text.keys
75                                 ()))
76     symbol_to_idx = {sym: i for i, sym in enumerate(
77         unique_symbols)}
78
79     one_hot = np.zeros((len(symbols), len(unique_symbols)
80                         ))
81     for i, sym in enumerate(symbols):
82         if sym in symbol_to_idx:
83             one_hot[i, symbol_to_idx[sym]] = 1
84
85     return one_hot
86
87 def demonstrate_embedding_enrichment():
88     """
89     Demonstriert die Anreicherung von Terminalzeichen mit
90     Embeddings
91     """
92     enricher = TerminalEmbeddingEnricher()
93
94     print("\n=== Anreicherung der Terminalzeichen mit
95           Embeddings ===")
96
97     # Beispielsequenz

```

```

92     sequence = ['KBG', 'VBG', 'KBBd', 'VBBd', 'KBA']
93
94     enriched = enricher.enrich_sequence(sequence)
95
96     print(f"\nSequenz: {' '.join(sequence)}")
97     print(f"Embedding-Dimension: {enriched['embeddings'].shape[1]}")
98     print(f"One-Hot-Dimension: {enriched['combined'].shape[1] - enriched['embeddings'].shape[1]}")
99     print(f"Kombinierte Dimension: {enriched['combined'].shape[1]}")
100
101     return enricher

```

Listing 16: Transformer-Embeddings für Terminalzeichen

4.3 Graph Neural Networks für die Nonterminal-Hierarchie

Die Nonterminal-Hierarchie wird als Graph Neural Network modelliert:

```

1  """
2  Graph Neural Network f r die Nonterminal-Hierarchie
3  Didaktische Implementierung mit PyTorch Geometric
4  """
5
6  import torch
7  import torch.nn as nn
8  import torch.nn.functional as F
9  from torch_geometric.nn import GCNConv, GATConv
10 from torch_geometric.data import Data
11 import networkx as nx
12
13 class GrammarGNN(nn.Module):
14     """
15     Graph Neural Network f r die Grammatik-Hierarchie
16     """
17
18     def __init__(self, input_dim, hidden_dim=64, num_classes=12):
19         super().__init__()
20         self.conv1 = GCNConv(input_dim, hidden_dim)

```

```

21         self.conv2 = GCNConv(hidden_dim, hidden_dim)
22         self.classifier = nn.Linear(hidden_dim, num_classes)
23
24     def forward(self, x, edge_index):
25         x = self.conv1(x, edge_index)
26         x = F.relu(x)
27         x = F.dropout(x, training=self.training)
28         x = self.conv2(x, edge_index)
29         x = F.relu(x)
30         x = self.classifier(x)
31         return F.log_softmax(x, dim=1)
32
33 class GrammarHierarchyGNN:
34     """
35     Verwaltet das GNN f r die Nonterminal-Hierarchie
36     """
37
38     def __init__(self, grammar_rules):
39         self.grammar = grammar_rules
40         self.graph = self._build_graph()
41         self.model = None
42
43     def _build_graph(self):
44         """
45         Baut einen Graphen aus der Grammatik-Hierarchie
46         """
47         G = nx.DiGraph()
48
49         # Knoten: Terminale und Nonterminale
50         all_symbols = set()
51
52         # Nonterminale als Knoten
53         for nt, productions in self.grammar.items():
54             all_symbols.add(nt)
55             for prod, _ in productions:
56                 for sym in prod:
57                     all_symbols.add(sym)
58
59         # Kanten: Ableitungsrelationen
60         for nt, productions in self.grammar.items():

```

```

61         for prod, prob in productions:
62             for sym in prod:
63                 G.add_edge(nt, sym, weight=prob)
64
65     return G
66
67 def prepare_data(self):
68     """
69     Bereitet die Daten f r das GNN vor
70     """
71     # Knoten-Indizes
72     nodes = list(self.graph.nodes())
73     node_to_idx = {node: i for i, node in enumerate(nodes
74                     )}
75
76     # Feature-Matrix (vereinfacht: One-Hot)
77     x = torch.eye(len(nodes))
78
79     # Kanten-Index
80     edge_index = []
81     for u, v, data in self.graph.edges(data=True):
82         edge_index.append([node_to_idx[u], node_to_idx[v
83                             ]])
84
85     edge_index = torch.tensor(edge_index, dtype=torch.
86                               long).t().contiguous()
87
88     return Data(x=x, edge_index=edge_index)
89
90 def train(self, epochs=100):
91     """
92     Trainiert das GNN
93     """
94     data = self.prepare_data()
95     self.model = GrammarGNN(input_dim=data.x.shape[1])
96
97     optimizer = torch.optim.Adam(self.model.parameters(),
98                                   lr=0.01)
99
100    print("\n=== Training des Grammar GNN ===")

```



```

97     for epoch in range(epochs):
98         self.model.train()
99         optimizer.zero_grad()
100         out = self.model(data.x, data.edge_index)
101
102         # Selbst berwachtes Lernen: Rekonstruktion des
103         # Graphen
104         # Vereinfacht: Vorhersage der Nachbarn
105         loss = F.nll_loss(out[data.edge_index[0]], data.
106                             edge_index[1])
107
108         loss.backward()
109         optimizer.step()
110
111         if epoch % 20 == 0:
112             print(f"Epoch {epoch}: Loss = {loss.item():.4
113                     f}")
114
115     return self.model
116
117 def demonstrate_gnn(grammar_rules):
118     """
119     Demonstriert das GNN f r die Grammatik-Hierarchie
120     """
121     print("\n=== Graph Neural Network f r Nonterminal-
122           Hierarchie ===")
123
124     gnn = GrammarHierarchyGNN(grammar_rules)
125     print(f"Graph: {gnn.graph.number_of_nodes()} Knoten, "
126           f"{gnn.graph.number_of_edges()} Kanten")
127
128     model = gnn.train(epochs=100)
129
130     return gnn, model

```

Listing 17: Graph Neural Network für Nonterminal-Hierarchie

4.4 Attention-Mechanismen für relevante Vorgänger

Attention-Mechanismen identifizieren besonders relevante Vorgänger für aktuelle Entscheidungen:

```
1  """
2  Attention-Mechanismen f r die Identifikation relevanter
   Vorgänger
3  """
4
5  import torch
6  import torch.nn as nn
7  import torch.nn.functional as F
8  import numpy as np
9
10 class SequenceAttention(nn.Module):
11     """
12     Attention-Mechanismus f r Sequenzmodellierung
13     """
14
15     def __init__(self, embedding_dim, hidden_dim=64):
16         super().__init__()
17         self.embedding_dim = embedding_dim
18         self.hidden_dim = hidden_dim
19
20         # Attention-Parameter
21         self.W_q = nn.Linear(embedding_dim, hidden_dim, bias=
            False)
22         self.W_k = nn.Linear(embedding_dim, hidden_dim, bias=
            False)
23         self.W_v = nn.Linear(embedding_dim, hidden_dim, bias=
            False)
24         self.scale = hidden_dim ** 0.5
25
26     def forward(self, x, mask=None):
27         """
28         x: (seq_len, batch, embedding_dim)
29         """
30         # Query, Key, Value berechnen
31         Q = self.W_q(x) # (seq_len, batch, hidden_dim)
32         K = self.W_k(x) # (seq_len, batch, hidden_dim)
```

```

33     V = self.W_v(x) # (seq_len, batch, hidden_dim)
34
35     # Attention-Scores
36     scores = torch.matmul(Q.transpose(0, 1), K.transpose
37                           (0, 1).transpose(1, 2))
38     scores = scores / self.scale
39
40     if mask is not None:
41         scores = scores.masked_fill(mask == 0, -1e9)
42
43     # Attention-Gewichte
44     attention_weights = F.softmax(scores, dim=-1)
45
46     # Gewichtete Summe
47     context = torch.matmul(attention_weights, V.transpose
48                           (0, 1))
49
50     return context, attention_weights
51
52 class SymbolPredictorWithAttention(nn.Module):
53     """
54     Sagt das n chste Symbol mit Attention auf die Vorg nger
55     vorher
56     """
57
58     def __init__(self, num_symbols, embedding_dim=50,
59                 hidden_dim=64):
60         super().__init__()
61         self.embedding = nn.Embedding(num_symbols,
62                                       embedding_dim)
63         self.attention = SequenceAttention(embedding_dim,
64                                           hidden_dim)
65         self.lstm = nn.LSTM(embedding_dim, hidden_dim,
66                             batch_first=True)
67         self.classifier = nn.Linear(hidden_dim +
68                                     embedding_dim, num_symbols)
69
70     def forward(self, x):
71         """
72         x: (batch, seq_len) mit Symbol-Indizes

```

```

65     """
66     # Embeddings
67     embedded = self.embedding(x) # (batch, seq_len,
        embedding_dim)
68
69     # LSTM f r sequenzielle Abh ngigkeiten
70     lstm_out, (hidden, cell) = self.lstm(embedded)
71
72     # Attention ber die Sequenz
73     # Transponieren f r Attention (seq_len, batch,
        embedding_dim)
74     context, attention_weights = self.attention(embedded.
        transpose(0, 1))
75
76     # Kombiniere letzten LSTM-State mit Attention-Context
77     last_hidden = hidden[-1] # (batch, hidden_dim)
78     last_context = context[-1] # (batch, hidden_dim)
79
80     # Vorhersage
81     combined = torch.cat([last_hidden, last_context], dim
        =-1)
82     logits = self.classifier(combined)
83
84     return logits, attention_weights
85
86 def demonstrate_attention(terminal_chains, symbol_to_idx):
87     """
88     Demonstriert Attention-Mechanismen auf den Sequenzen
89     """
90     print("\n=== Attention-Mechanismen f r relevante
        Vorg nger ===")
91
92     # Daten vorbereiten
93     sequences = []
94     for chain in terminal_chains:
95         seq = [symbol_to_idx[sym] for sym in chain]
96         sequences.append(seq)
97
98     # Padding f r Batch-Verarbeitung
99     from torch.nn.utils.rnn import pad_sequence

```

```

100     sequences_padded = pad_sequence([torch.tensor(seq) for
101                                     seq in sequences],
102                                     batch_first=True,
103                                     padding_value=0)
104
105     # Modell initialisieren
106     model = SymbolPredictorWithAttention(num_symbols=len(
107         symbol_to_idx))
108
109     # Forward-Pass
110     logits, attention_weights = model(sequences_padded[:2])
111     # Nur erste 2 Sequenzen
112
113     print(f"\nInput-Shape: {sequences_padded[:2].shape}")
114     print(f"Attention-Weights-Shape: {attention_weights.shape}")
115     print(f"Logits-Shape: {logits.shape}")
116
117     # Visualisierung der Attention-Gewichte
118     plot_attention_weights(attention_weights[0].detach().
119                           numpy(),
120                           sequences[0], sequences[0])
121
122     return model
123
124 def plot_attention_weights(attention, source_tokens,
125 target_tokens):
126     """
127     Visualisiert Attention-Gewichte als Heatmap
128     """
129     import matplotlib.pyplot as plt
130     import seaborn as sns
131
132     plt.figure(figsize=(10, 8))
133     sns.heatmap(attention[:len(target_tokens), :len(
134         source_tokens)],
135                 xticklabels=source_tokens,
136                 yticklabels=target_tokens,
137                 cmap='viridis', annot=True, fmt='.2f')
138     plt.title('Attention-Gewichte zwischen Vorgängern und

```

```

132     Vorhersage')
133     plt.xlabel('Vorgänger-Symbole')
134     plt.ylabel('Vorhersage-Position')
135     plt.tight_layout()
136     plt.savefig('attention_weights.png', dpi=150)
137     plt.show()

```

Listing 18: Attention-Mechanismen für Sequenzmodellierung

4.5 Integration der Komponenten in Szenario D

Die vollständige Integration aller Komponenten in Szenario D:

```

1  """
2  Szenario D: Hybride Modellierung
3  Integration computerlinguistischer Verfahren mit
4  interpretativen Kategorien
5  """
6  import json
7  import numpy as np
8
9  class SzenarioD:
10     """
11     Integriert computerlinguistische Verfahren komplementär
12     zu den
13     interpretativ gebildeten Kategorien der ARS 3.0
14     """
15     def __init__(self, terminal_chains, grammar_rules,
16                  reflection_log):
17         self.terminal_chains = terminal_chains
18         self.grammar_rules = grammar_rules
19         self.reflection_log = reflection_log
20         self.results = {}
21
22         print("\n" + "="*70)
23         print("SZENARIO D: HYBRIDE MODELLIERUNG")
24         print("="*70)
25         print("\nDieses Szenario integriert
26             computerlinguistische")

```

```

25     print("Verfahren KOMPLEMENT R zu den interpretativen
26           ")
27     print("Kategorien der ARS 3.0. Die interpretative
28           Basis")
29     print("bleibt erhalten, wird aber durch neue
30           Verfahren")
31     print("angereichert.\n")
32
33     def run_crf_modeling(self):
34         """
35         F hrt CRF-Modellierung auf den Terminalzeichen durch
36         """
37         print("\n--- CRF-Modellierung ---")
38         crf_model = demonstrate_crf(self.terminal_chains)
39         self.results['crf'] = {'model': crf_model}
40         return crf_model
41
42     def run_embedding_enrichment(self):
43         """
44         Reichert Terminalzeichen mit Transformer-Embeddings
45         an
46         """
47         print("\n--- Embedding-Anreicherung ---")
48         enricher = demonstrate_embedding_enrichment()
49
50         # Beispiel f r angereicherte Sequenz
51         example_seq = self.terminal_chains[0][:5]
52         enriched = enricher.enrich_sequence(example_seq)
53
54         self.results['embeddings'] = {
55             'enricher': enricher,
56             'example': enriched
57         }
58
59         return enricher
60
61     def run_gnn_hierarchy(self):
62         """
63         Modelliert die Nonterminal-Hierarchie als GNN
64         """

```

```

61     print("\n--- GNN f r Nonterminal-Hierarchie ---")
62     gnn, model = demonstrate_gnn(self.grammar_rules)
63     self.results['gnn'] = {'gnn': gnn, 'model': model}
64     return gnn, model
65
66 def run_attention_analysis(self):
67     """
68     Analysiert Attention-Mechanismen auf den Sequenzen
69     """
70     print("\n--- Attention-Analyse ---")
71
72     # Symbol zu Index Mapping
73     all_symbols = set()
74     for chain in self.terminal_chains:
75         all_symbols.update(chain)
76     symbol_to_idx = {sym: i for i, sym in enumerate(
77         sorted(all_symbols))}
78
79     model = demonstrate_attention(self.terminal_chains,
80         symbol_to_idx)
81     self.results['attention'] = {'model': model}
82
83     return model
84
85 def run_all(self):
86     """
87     F hrt alle Analysen aus (komplement r, nicht
88     ersetzend)
89     """
90     self.run_crf_modeling()
91     self.run_embedding_enrichment()
92     self.run_gnn_hierarchy()
93     self.run_attention_analysis()
94
95     # Zusammenfassung
96     print("\n" + "="*70)
97     print("ZUSAMMENFASSUNG SZENARIO D")
98     print("="*70)
99     print("      CRF-Modellierung: Sequenzielle
100         Abh ngigkeiten modelliert")

```



```

197         print("      Embedding-Anreicherung: Terminalzeichen
198               semantisch angereichert")
199         print("      GNN-Hierarchie: Nonterminal-Struktur als
200               Graph modelliert")
201         print("      Attention-Analyse: Relevante Vorgänger
202               identifiziert")
203         print("\nDie interpretativen Kategorien der ARS 3.0
204               bleiben")
205         print("die Grundlage aller Analysen. Die
206               computerlinguistischen")
207         print("Verfahren dienen der komplementären
208               Erkenntnisgewinnung.")
209
210         return self.results
211
212 def run_scenario_d_demonstration(terminal_chains,
213     grammar_rules, reflection_log):
214     """
215     Führt die vollständige Demonstration von Szenario D aus
216     """
217     scenario = ScenarioD(terminal_chains, grammar_rules,
218         reflection_log)
219     results = scenario.run_all()
220
221     # Speichere Ergebnisse
222     with open('scenario_d_results.json', 'w') as f:
223         # Vereinfachte serialisierbare Version
224         serializable = {
225             'crf': {'status': 'completed'},
226             'embeddings': {'status': 'completed'},
227             'gnn': {'num_nodes': results['gnn'][0].graph.
228                 number_of_nodes()},
229             'attention': {'status': 'completed'}
230         }
231         json.dump(serializable, f, indent=2)
232
233     print("\nErgebnisse gespeichert in 'scenario_d_results.
234           json'")
235
236     return results

```

```

127
128 # Didaktischer Hinweis
129 print("\n" + "="*70)
130 print("METHODOLOGISCHER HINWEIS ZU SZENARIO D")
131 print("="*70)
132 print("Szenario D beh lt die interpretative Basis der ARS
      3.0 bei.")
133 print("Die computerlinguistischen Verfahren werden
      KOMPLEMENT R")
134 print("eingesetzt, nicht als Ersatz der manuellen
      Kategorienbildung.")
135 print("Dies entspricht der methodologischen Forderung nach")
136 print("Kontrolle und Transparenz im Sinne der XAI-Kriterien."
      )

```

Listing 19: Szenario D - Vollständige hybride Integration

5 Vergleich der Szenarien und methodologische Reflexion

5.1 Gegenüberstellung der Ansätze

Tabelle 2: Vergleich der Szenarien C und D

Kriterium	Szenario C	Szenario D
Kategorienbildung	Automatisch (Speech Act Recognition)	Interpretativ (ARS 3.0)
Datenbasis	Augmentierte Rohdaten	Terminalzeichenketten
Repräsentation	Vektorielle Embeddings	Diskrete Kategorien + Embeddings
Hierarchie	Automatisch gelernt	Explizit induziert (ARS 3.0)
Transparenz	Gering (Black Box)	Hoch (dokumentierte Entscheidungen)
Didaktischer Wert	Funktionsweise neuronaler Verfahren	Integration alter und neuer Methoden
Empirische Validität	Nicht gegeben	Eingeschränkt (basierend auf Interpretation)
Methodologische Kontrolle	Verloren	Erhalten

5.2 Didaktische Erkenntnisse aus Szenario C

Die Implementierung von Szenario C hat gezeigt:

1. **Notwendigkeit großer Datenmengen:** Neuronale Verfahren benötigen für valide Ergebnisse Datenmengen, die weit über die acht Transkripte hinausgehen. Die Augmentierung ermöglicht zwar die Demonstration der Funktionsweise, ersetzt aber keine echten Daten.
2. **Opazität der Entscheidungen:** Die automatisch gelernten Kategorien und Attention-Gewichte sind für Dritte nicht ohne weiteres nachvollziehbar. Die XAI-Kriterien der Verständlichkeit und Transparenz werden verletzt.
3. **Verlust der interpretativen Basis:** Die automatische Speech Act Recognition bildet nicht die qualitativ gehaltvollen Unterscheidungen der ARS ab (z.B. zwischen KBA und KAA), sondern lernt statistische Korrelationen im Vektorraum.

5.3 Didaktische Erkenntnisse aus Szenario D

Die Implementierung von Szenario D hat gezeigt:

1. **Komplementarität statt Substitution:** Die computerlinguistischen Verfahren können wertvolle Zusatzinformationen liefern (z.B. semantische Ähnlichkeiten zwischen verschiedenen Äußerungen), ohne die interpretative Basis zu ersetzen.
2. **Validierungsmöglichkeiten:** Die Embedding-Ähnlichkeiten können zur Validierung der interpretativen Kategorienbildung genutzt werden: Ähnliche Äußerungen sollten ähnliche Terminalzeichen erhalten.
3. **Visualisierung von Abhängigkeiten:** Attention-Mechanismen und CRF-Modelle visualisieren, welche Vorgänger für aktuelle Entscheidungen besonders relevant sind – dies kann die sequenzielle Struktur der Gespräche veranschaulichen.
4. **Methodologische Kontrolle bleibt erhalten:** Da die interpretativen Kategorien die Grundlage bilden, bleiben alle Ergebnisse an die qualitativen Entscheidungen rückgebunden und intersubjektiv prüfbar.

5.4 Fazit für die Lehrpraxis

Die didaktische Exploration der Szenarien C und D führt zu folgenden Schlussfolgerungen:

1. **Szenario C eignet sich zur Demonstration der Funktionsweise** neuraler Verfahren, sollte aber mit explizitem Hinweis auf die fehlende empirische Validität und die methodologischen Probleme eingesetzt werden.
2. **Szenario D ist methodologisch vorzuziehen**, da es die interpretative Basis erhält und computerlinguistische Verfahren komplementär nutzt. Es vermittelt, wie alte und neue Methoden produktiv verbunden werden können.
3. **Data Augmentation ist ein wertvolles didaktisches Werkzeug**, um mit kleinen Datensätzen die Funktionsweise von Verfahren zu demonstrieren. Der augmentierte Charakter der Daten muss dabei stets transparent gemacht werden.
4. **Die XAI-Kriterien** (Verständlichkeit, Genauigkeit, Wissensgrenzen) bieten einen geeigneten Rahmen, um die verschiedenen Ansätze zu bewerten und ihre Stärken und Schwächen zu reflektieren.

6 Ausblick

Die hier vorgestellten didaktischen Implementierungen können in mehreren Richtungen weiterentwickelt werden:

1. **Erweiterung der Augmentierungsstrategien:** Über einfaches Kopieren hinaus könnten komplexere Augmentierungen (Paraphrasierung, kontrollierte Variation) implementiert werden.
2. **Integration weiterer Verfahren:** z.B. PETRI-Netze für Nebenläufigkeit, Bayessche Netze für Inferenz, oder formale Verifikationsmethoden.
3. **Entwicklung von Vergleichsmetriken:** Wie kann man die Ergebnisse der verschiedenen Szenarien quantitativ vergleichen, ohne die qualitative Basis zu verlieren?
4. **Übertragung auf andere Datensätze:** Die Methodik lässt sich auf andere Interaktionstypen übertragen (Arzt-Patient-Gespräche, Unterrichtsinteraktionen, etc.).

Entscheidend bleibt dabei stets die methodologische Kontrolle: Die formalen Verfahren müssen den interpretativen Charakter der Analyse respektieren und dürfen nicht zu dessen Automatisierung führen.

Literatur

- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bannetot, A., Tabik, S., Barredo, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of NAACL-HLT 2019*, 4171-4186.
- Flick, U. (2019). *Qualitative Sozialforschung: Eine Einführung* (9. Aufl.). Rowohlt.
- Lafferty, J., McCallum, A., & Pereira, F. (2001). Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data. *Proceedings of ICML 2001*, 282-289.
- Mann, W. C., & Thompson, S. A. (1988). Rhetorical Structure Theory: Toward a functional theory of text organization. *Text*, 8(3), 243-281.
- Przyborski, A., & Wohlrab-Sahr, M. (2021). *Qualitative Sozialforschung: Ein Arbeitsbuch* (5. Aufl.). De Gruyter Oldenbourg.
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks. *Proceedings of EMNLP-IJCNLP 2019*, 3982-3992.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems 30*, 5998-6008.