

Algorithmisch Rekursive Sequenzanalyse 4.0

Hybride Integration computerlinguistischer
Verfahren
als komplementäre Erweiterung der ARS 3.0

Paul Koop

2026

Zusammenfassung

Die vorliegende Arbeit entwickelt eine hybride Integration computerlinguistischer Verfahren in die Algorithmisch Rekursive Sequenzanalyse (ARS). Im Unterschied zu Szenario C, das eine vollständige Automatisierung der Kategorienbildung anstrebt, werden hier computerlinguistische Methoden komplementär zu den interpretativ gewonnenen Kategorien der ARS 3.0 eingesetzt. Die Integration umfasst Conditional Random Fields (CRF) für sequenzielle Abhängigkeiten, Transformer-Embeddings zur semantischen Anreicherung, Graph Neural Networks (GNN) für die Nonterminal-Hierarchie und Attention-Mechanismen zur Identifikation relevanter Vorgänger. Die methodologische Kontrolle bleibt gewahrt, da die interpretativen Kategorien die Grundlage aller Analysen bilden und die computerlinguistischen Verfahren lediglich zusätzliche Erkenntnisdimensionen eröffnen. Die Anwendung auf acht Transkripte von Verkaufsgesprächen demonstriert den Mehrwert dieser komplementären Integration.

Inhaltsverzeichnis

1	Einleitung: Komplementarität statt Substitution	2
2	Theoretische Grundlagen	2
2.1	Conditional Random Fields (CRF)	2
2.2	Transformer-Embeddings	3
2.3	Graph Neural Networks (GNN)	3
2.4	Attention-Mechanismen	3
3	Methodik: Komplementäre Integration	3
3.1	CRF für sequenzielle Abhängigkeiten	3
3.2	Transformer-Embeddings zur semantischen Validierung	4
3.3	GNN für Strukturanalyse	4
3.4	Attention für relevante Kontexte	4
4	Implementierung	4
5	Beispielausgabe	22
6	Diskussion	25
6.1	Methodologische Bewertung	25
6.2	Mehrwert der hybriden Integration	26
6.3	Interpretation der Ergebnisse	26
6.4	Grenzen	27
7	Fazit und Ausblick	27
A	Die acht Transkripte mit Terminalzeichen	29
A.1	Transkript 1 - Metzgerei	29
A.2	Transkript 2 - Marktplatz (Kirschen)	29
A.3	Transkript 3 - Fischstand	29
A.4	Transkript 4 - Gemüsestand (ausführlich)	29
A.5	Transkript 5 - Gemüsestand (mit KAV zu Beginn)	29
A.6	Transkript 6 - Käseverkaufsstand	29
A.7	Transkript 7 - Bonbonstand	29
A.8	Transkript 8 - Bäckerei	29

1 Einleitung: Komplementarität statt Substitution

Die ARS 3.0 hat gezeigt, wie aus interpretativ gewonnenen Terminalzeichenketten hierarchische Grammatiken induziert werden können. Diese Grammatiken sind transparent, intersubjektiv prüfbar und methodologisch kontrolliert. Sie bilden die Grundlage für alle weiteren Analysen.

Die computerlinguistischen Verfahren, die in Szenario C entwickelt wurden, bieten zusätzliche Analyseperspektiven:

- **Conditional Random Fields** modellieren sequenzielle Abhängigkeiten mit Kontext
- **Transformer-Embeddings** quantifizieren semantische Ähnlichkeiten
- **Graph Neural Networks** erfassen strukturelle Zusammenhänge
- **Attention-Mechanismen** identifizieren relevante Vorgänger

Anders als in Szenario C werden diese Verfahren hier jedoch nicht zur Automatisierung der Kategorienbildung eingesetzt, sondern als komplementäre Erweiterung. Die interpretativen Kategorien bleiben die Grundlage – die computerlinguistischen Verfahren eröffnen zusätzliche Erkenntnisdimensionen, ohne die methodologische Kontrolle zu gefährden.

2 Theoretische Grundlagen

2.1 Conditional Random Fields (CRF)

Conditional Random Fields (Lafferty et al., 2001) sind probabilistische graphische Modelle zur Segmentierung und Labeling von Sequenzdaten. Im Gegensatz zu HMM modellieren sie direkt die bedingte Wahrscheinlichkeit $P(Y|X)$ und können beliebig viele kontextuelle Features integrieren.

Für ARS 4.0 werden CRF verwendet, um die Abhängigkeit der Terminalzeichen vom weiteren Kontext zu modellieren – nicht nur vom unmittelbaren Vorgänger.

2.2 Transformer-Embeddings

Transformer-Embeddings (Devlin et al., 2019; Reimers & Gurevych, 2019) erzeugen kontextualisierte Vektorrepräsentationen von Texten. Im Gegensatz zu statischen Word Embeddings berücksichtigen sie den gesamten Satzkontext.

Für ARS 4.0 werden Transformer-Embeddings genutzt, um die semantische Ähnlichkeit zwischen verschiedenen Äußerungen zu quantifizieren – auch solchen, die unterschiedliche Terminalzeichen erhalten haben.

2.3 Graph Neural Networks (GNN)

Graph Neural Networks (Scarselli et al., 2009) operieren direkt auf Graphstrukturen und lernen Repräsentationen für Knoten unter Berücksichtigung ihrer Nachbarn.

Für ARS 4.0 wird die Nonterminal-Hierarchie als Graph modelliert, wobei Knoten Terminale und Nonterminale repräsentieren und Kanten die Ableitungsrelationen darstellen.

2.4 Attention-Mechanismen

Attention-Mechanismen (Vaswani et al., 2017) erlauben es Modellen, bei der Vorhersage unterschiedlich stark auf verschiedene Teile der Eingabe zu fokussieren.

Für ARS 4.0 werden Attention-Mechanismen genutzt, um zu identifizieren, welche Vorgänger für die Vorhersage des nächsten Symbols besonders relevant sind.

3 Methodik: Komplementäre Integration

3.1 CRF für sequenzielle Abhängigkeiten

CRF werden auf den Terminalzeichenketten trainiert, um zu lernen, welche Kontextfaktoren die Wahl des nächsten Symbols beeinflussen. Die Features umfassen:

- Aktuelles Symbol
- Vorheriges Symbol
- Nächstes Symbol (wenn bekannt)
- Position in der Sequenz
- Sprecherwechsel-Indikator

- Phasen-Indikator (aus HMM)

3.2 Transformer-Embeddings zur semantischen Validierung

Transformer-Embeddings werden genutzt, um die semantische Ähnlichkeit zwischen Äußerungen zu berechnen, die das gleiche Terminalzeichen erhalten haben. Dies dient der Validierung der interpretativen Kategorienbildung:

- Hohe Ähnlichkeit innerhalb einer Kategorie spricht für konsistente Interpretation
- Überlappungen zwischen Kategorien können auf Interpretationsspielräume hinweisen

3.3 GNN für Strukturanalyse

Die Nonterminal-Hierarchie wird als Graph modelliert und mit einem GNN analysiert. Dies ermöglicht:

- Identifikation zentraler Knoten (wichtige Nonterminale)
- Erkennung von Mustern in der Ableitungsstruktur
- Visualisierung der Hierarchie als Embedding-Raum

3.4 Attention für relevante Kontexte

Attention-Mechanismen werden auf den Sequenzen trainiert, um zu visualisieren, welche Vorgänger für die Vorhersage des nächsten Symbols besonders wichtig sind. Dies kann:

- Die Plausibilität der ARS-Grammatik bestätigen
- Auf bisher übersehene Abhängigkeiten hinweisen
- Die sequenzielle Struktur der Gespräche veranschaulichen

4 Implementierung

```

1  """
2  ARS 4.0 - Hybride Integration
3  Komplement re Nutzung computerlinguistischer Verfahren
4  mit interpretativen Kategorien der ARS 3.0

```

```

5  """
6
7  import numpy as np
8  import matplotlib.pyplot as plt
9  import seaborn as sns
10 from collections import defaultdict
11 import networkx as nx
12 from sklearn_crfsuite import CRF
13 from sentence_transformers import SentenceTransformer
14 import torch
15 import torch.nn as nn
16 import torch.nn.functional as F
17
18 #
19 # =====
20 # 1. CONDITIONAL RANDOM FIELDS (CRF)
21 #
22 # =====
23
24 class ARSCRFModel:
25     """
26     CRF-Modell f r sequenzielle Abh ngigkeiten in
27     Terminalzeichenketten
28     """
29
30     def __init__(self):
31         self.crf = CRF(
32             algorithm='lbfgs',
33             c1=0.1, # L1-Regularisierung
34             c2=0.1, # L2-Regularisierung
35             max_iterations=100,
36             all_possible_transitions=True
37         )
38         self.feature_names = []
39
40     def extract_features(self, sequence, i):
41         """
42         Extrahiert Features f r Position i in der Sequenz

```

```

40     """
41     features = {
42         'bias': 1.0,
43         'symbol': sequence[i],
44         'symbol.prefix_K': sequence[i].startswith('K'),
45         'symbol.prefix_V': sequence[i].startswith('V'),
46         'symbol.suffix_A': sequence[i].endswith('A'),
47         'symbol.suffix_B': sequence[i].endswith('B'),
48         'symbol.suffix_E': sequence[i].endswith('E'),
49         'symbol.suffix_G': sequence[i].endswith('G'),
50         'symbol.suffix_V': sequence[i].endswith('V'),
51         'position': i,
52         'is_first': i == 0,
53         'is_last': i == len(sequence) - 1,
54     }
55
56     # Kontext-Features (-2, -1, +1, +2)
57     for offset in [-2, -1, 1, 2]:
58         if 0 <= i + offset < len(sequence):
59             sym = sequence[i + offset]
60             features[f'context_{offset:+d}'] = sym
61             features[f'context_{offset:+d}.prefix_K'] =
62                 sym.startswith('K')
63             features[f'context_{offset:+d}.prefix_V'] =
64                 sym.startswith('V')
65
66     # Bigram-Features
67     if i > 0:
68         features['bigram'] = f"{sequence[i-1]}_{sequence[
69             i]}"
70
71     return features
72
73 def prepare_data(self, sequences):
74     """
75     Bereitet Daten f r CRF-Training vor
76     """
77     X = []
78     y = []

```



```

77     for seq in sequences:
78         X_seq = [self.extract_features(seq, i) for i in
79                     range(len(seq))]
80         y_seq = [sym for sym in seq]
81         X.append(X_seq)
82         y.append(y_seq)
83
84     return X, y
85
86 def fit(self, sequences):
87     """
88     Trainiert das CRF-Modell
89     """
90     print("\n=== CRF-Training ===")
91     X, y = self.prepare_data(sequences)
92     self.crf.fit(X, y)
93
94     # Wichtigste Features anzeigen
95     self.print_top_features()
96
97     return self
98
99 def predict(self, sequence):
100     """
101     Sagt Labels f r eine Sequenz vorher
102     """
103     X = [self.extract_features(sequence, i) for i in
104           range(len(sequence))]
105     return self.crf.predict([X])[0]
106
107 def print_top_features(self):
108     """
109     Zeigt die wichtigsten CRF-Features an
110     """
111     print("\nTop 20 CRF-Features:")
112     top_features = sorted(
113         self.crf.state_features_.items(),
114         key=lambda x: abs(x[1]),
115         reverse=True
116     )[:20]

```

```

115         for (attr, label), weight in top_features:
116             print(f" {attr:30s} -> {label:4s} : {weight:+.4f}
117                   ")
118
119 #
120 # =====
121 # 2. TRANSFORMER-EMBEDDINGS F R SEMANTISCHE VALIDIERUNG
122 # =====
123
124 class SemanticValidator:
125     """
126     Validiert interpretative Kategorien mit Transformer-
127     Embeddings
128     """
129
130     def __init__(self, model_name='paraphrase-multilingual-
131 MiniLM-L12-v2'):
132         print(f"\n=== Lade Sentence-Transformer: {model_name}
133             ===")
134         self.model = SentenceTransformer(model_name)
135         self.symbol_to_texts = self._create_text_mapping()
136         self.embeddings = {}
137
138     def _create_text_mapping(self):
139         """
140         Erstellt Mapping von Terminalzeichen zu
141         Beispieltexten
142         """
143         return {
144             'KBG': ['Guten Tag', 'Guten Morgen', 'Hallo', '
145 Gr Gott'],
146             'VBG': ['Guten Tag', 'Guten Morgen', 'Hallo
147 zur ck', 'Willkommen'],
148             'KBBd': ['Einmal Leberwurst', 'Ich h tte gerne
149 K se', 'Ein Kilo pfel bitte'],

```

```

142         'VBbD': ['Wie viel darf es sein?', 'Welche Sorte?
143                 ', 'Sonst noch etwas?'],
144         'KBA': ['Zweihundert Gramm', 'Die hellen bitte',
145                 'Ja, gerne'],
146         'VBA': ['In Ordnung', 'Kommt sofort', 'Alles klar
147                 '],
148         'KAE': ['Kann ich das in Salat tun?', 'Woher
149                 kommen die?', 'Ist das frisch?'],
150         'VAE': ['Eher anbraten', 'Aus der Region', 'Ja,
151                 ganz frisch'],
152         'KAA': ['Bitte', 'Danke', 'Ja, danke'],
153         'VAA': ['Das macht 8 Mark 20', '3 Mark bitte', '
154                 14 Mark 19'],
155         'KAV': ['Auf Wiedersehen', 'Tsch ss', 'Einen
156                 sch nen Tag'],
157         'VAV': ['Vielen Dank', 'Sch nen Tag noch', 'Auf
158                 Wiedersehen']
159     }
160
161     def compute_category_embeddings(self):
162         """
163         Berechnet Durchschnitts-Embeddings f r jede
164         Kategorie
165         """
166         for symbol, texts in self.symbol_to_texts.items():
167             embeddings = self.model.encode(texts)
168             self.embeddings[symbol] = np.mean(embeddings,
169                                                 axis=0)
170
171         return self.embeddings
172
173     def compute_similarity_matrix(self):
174         """
175         Berechnet hnlichkeitsmatrix zwischen Kategorien
176         """
177         if not self.embeddings:
178             self.compute_category_embeddings()
179
180         symbols = sorted(self.embeddings.keys())
181         n = len(symbols)

```

```

172     sim_matrix = np.zeros((n, n))
173
174     for i, sym1 in enumerate(symbols):
175         for j, sym2 in enumerate(symbols):
176             emb1 = self.embeddings[sym1]
177             emb2 = self.embeddings[sym2]
178             sim = np.dot(emb1, emb2) / (np.linalg.norm(
179                 emb1) * np.linalg.norm(emb2))
180             sim_matrix[i, j] = sim
181
182     return sim_matrix, symbols
183
184 def validate_categories(self):
185     """
186     Validiert die interpretativen Kategorien
187     """
188     print("\n=== Validierung der interpretativen
189           Kategorien ===")
190
191     sim_matrix, symbols = self.compute_similarity_matrix
192         ()
193
194     # Statistik pro Kategorie
195     print("\nIntra-Kategorie- hnlichkeit (Koh sion):")
196     for i, sym in enumerate(symbols):
197         intra = sim_matrix[i, i]
198         print(f" {sym}: {intra:.3f}")
199
200     # Inter-Kategorie- hnlichkeit
201     print("\nInter-Kategorie- hnlichkeit (h chste 10):"
202         )
203     similarities = []
204     for i in range(len(symbols)):
205         for j in range(i+1, len(symbols)):
206             similarities.append((symbols[i], symbols[j],
207                 sim_matrix[i, j]))
208
209     similarities.sort(key=lambda x: x[2], reverse=True)
210     for sym1, sym2, sim in similarities[:10]:
211         print(f" {sym1} - {sym2}: {sim:.3f}")

```

```

207
208     # Visualisierung
209     self.visualize_similarity_matrix(sim_matrix, symbols)
210
211     return sim_matrix, symbols
212
213 def visualize_similarity_matrix(self, sim_matrix, symbols
214 ):
215     """
216     Visualisiert die hnlichkeitsmatrix als Heatmap
217     """
218     plt.figure(figsize=(12, 10))
219     sns.heatmap(sim_matrix,
220                 xticklabels=symbols,
221                 yticklabels=symbols,
222                 cmap='viridis',
223                 vmin=0, vmax=1,
224                 annot=True, fmt='.2f')
225     plt.title('Semantische hnlichkeit zwischen
226               Terminalzeichen-Kategorien')
227     plt.tight_layout()
228     plt.savefig('category_similarity.png', dpi=150)
229     plt.show()
230
231 #
232
233 # 3. GRAPH NEURAL NETWORK F R NONTERMINAL-HIERARCHIE
234 #
235
236
237
238 class GrammarGraph:
239     """
240     Repr sentiert die ARS-Grammatik als Graph
241     """
242
243     def __init__(self, grammar_rules):
244         self.grammar = grammar_rules
245         self.graph = nx.DiGraph()

```

```

241         self.build_graph()
242
243     def build_graph(self):
244         """
245         Baut einen gerichteten Graphen aus der Grammatik
246         """
247         for nt, productions in self.grammar.items():
248             for prod, prob in productions:
249                 for sym in prod:
250                     self.graph.add_edge(nt, sym, weight=prob,
251                                         type='derivation')
252
253         # Metriken berechnen
254         print("\n=== Grammatik-Graph Analyse ===")
255         print(f"Knoten: {self.graph.number_of_nodes()}")
256         print(f"Kanten: {self.graph.number_of_edges()}")
257
258         # Zentralit t
259         if self.graph.number_of_nodes() > 0:
260             centrality = nx.degree_centrality(self.graph)
261             top_nodes = sorted(centrality.items(), key=lambda
262                               x: x[1], reverse=True)[:5]
263             print("\nTop 5 Knoten nach Zentralit t:")
264             for node, cent in top_nodes:
265                 print(f"    {node}: {cent:.3f}")
266
267     def visualize(self, filename="grammar_graph.png"):
268         """
269         Visualisiert den Grammatik-Graphen
270         """
271         plt.figure(figsize=(15, 10))
272
273         # Layout
274         pos = nx.spring_layout(self.graph, k=2, iterations
275                               =50)
276
277         # Knoten nach Typ f rben
278         node_colors = []
279         for node in self.graph.nodes():
280             if node.startswith('NT_'):

```

```

278         node_colors.append('lightgreen')    #
279         Nonterminale
280     else:
281         node_colors.append('lightblue')    # Terminale
282
283     nx.draw(self.graph, pos,
284             node_color=node_colors,
285             with_labels=True,
286             node_size=1000,
287             font_size=8,
288             arrows=True,
289             arrowsize=20,
290             edge_color='gray',
291             alpha=0.7)
292
293     plt.title('ARS-Grammatik als Graph')
294     plt.tight_layout()
295     plt.savefig(filename, dpi=150)
296     plt.show()
297
298 class SimpleGNN(nn.Module):
299     """
300     Einfaches Graph Neural Network f r Analysezwecke
301     """
302
303     def __init__(self, input_dim, hidden_dim=16, output_dim
304                 =8):
305         super().__init__()
306         self.conv1 = nn.Linear(input_dim, hidden_dim)
307         self.conv2 = nn.Linear(hidden_dim, hidden_dim)
308         self.output = nn.Linear(hidden_dim, output_dim)
309
310     def forward(self, x, adj):
311         # Einfache Graph-Konvolution (vereinfacht)
312         # x: Knoten-Features, adj: Adjazenzmatrix
313         x = torch.relu(self.conv1(torch.mm(adj, x)))
314         x = torch.relu(self.conv2(torch.mm(adj, x)))
315         return self.output(x)

```

```

315 #
    =====
316 # 4. ATTENTION-MECHANISMEN FÜR RELEVANTE VORGÄNGE
317 #
    =====
318
319 class AttentionVisualizer:
320     """
321     Visualisiert Attention-Mechanismen auf Sequenzen
322     """
323
324     def __init__(self, terminal_chains):
325         self.chains = terminal_chains
326         self.symbols = sorted(set([sym for chain in chains
327                                   for sym in chain]))
327         self.symbol_to_idx = {sym: i for i, sym in enumerate(
328                                 self.symbols)}
329
330     def compute_bigram_probs(self):
331         """
332         Berechnet Bigram-Wahrscheinlichkeiten aus den Daten
333         """
334         bigram_counts = defaultdict(int)
335         unigram_counts = defaultdict(int)
336
337         for chain in self.chains:
338             for i in range(len(chain)-1):
339                 bigram_counts[(chain[i], chain[i+1])] += 1
340                 unigram_counts[chain[i]] += 1
341
342         # Letztes Symbol auch zählen
343         if chain:
344             unigram_counts[chain[-1]] += 1
345
346         # Wahrscheinlichkeiten
347         bigram_probs = {}
348         for (prev, next_), count in bigram_counts.items():

```



```

348         bigram_probs[(prev, next_)] = count /
           unigram_counts[prev]
349
350     return bigram_probs
351
352     def compute_attention_weights(self, sequence):
353         """
354         Berechnet vereinfachte Attention-Gewichte
355         """
356         bigram_probs = self.compute_bigram_probs()
357         n = len(sequence)
358         attention = np.zeros((n, n))
359
360         for i in range(1, n): # F r jede Position ab der
           zweiten
361             prev = sequence[i-1]
362             current = sequence[i]
363
364             # Attention auf Vorg nger basierend auf Bigram-
           Wahrscheinlichkeit
365             if (prev, current) in bigram_probs:
366                 attention[i, i-1] = bigram_probs[(prev,
           current)]
367
368             # Auch entferntere Vorg nger (exponentiell
           abfallend)
369             for j in range(i-2, -1, -1):
370                 attention[i, j] = attention[i, j+1] * 0.5
371
372             # Normalisierung
373             for i in range(n):
374                 row_sum = attention[i].sum()
375                 if row_sum > 0:
376                     attention[i] /= row_sum
377
378             return attention
379
380     def visualize_attention(self, sequence, title="Attention-
           Gewichte"):
381         """

```

```

382     Visualisiert Attention-Gewichte als Heatmap
383     """
384     attention = self.compute_attention_weights(sequence)
385
386     plt.figure(figsize=(10, 8))
387     sns.heatmap(attention,
388                 xticklabels=sequence,
389                 yticklabels=sequence,
390                 cmap='viridis',
391                 annot=True, fmt='.2f')
392
393     plt.title(title)
394     plt.xlabel('Vorgänger')
395     plt.ylabel('Aktuelle Position')
396     plt.tight_layout()
397     plt.savefig('attention_weights.png', dpi=150)
398     plt.show()
399
400     return attention
401
402 #
403
404 =====
405
406 # 5. INTEGRATION: HYBRIDER ANALYZER
407 #
408
409 =====
410
411 class HybridAnalyzer:
412     """
413     Integriert alle komplementären Verfahren
414     """
415
416     def __init__(self, terminal_chains, grammar_rules,
417                  transcripts):
418         self.chains = terminal_chains
419         self.grammar = grammar_rules
420         self.transcripts = transcripts
421
422         self.crf_model = None
423         self.semantic_validator = None

```

```

417     self.grammar_graph = None
418     self.attention_viz = None
419
420     print("\n" + "="*70)
421     print("ARS 4.0 - HYBRIDER ANALYZER")
422     print("="*70)
423     print("\nDieser Analyzer nutzt computerlinguistische
         Verfahren")
424     print("KOMPLEMENT R zu den interpretativen
         Kategorien.")
425     print("Die Basis bleibt die ARS-3.0-Grammatik.\n")
426
427     def run_crf_analysis(self):
428         """
429         F hrt CRF-Analyse durch
430         """
431         print("\n" + "-"*50)
432         print("1. CRF-Analyse")
433         print("-"*50)
434
435         self.crf_model = ARSCRFModel()
436         self.crf_model.fit(self.chains)
437
438         # Beispieldvorhersage
439         example = self.chains[0][:5]
440         pred = self.crf_model.predict(example)
441         print(f"\nBeispiel-Vorhersage f r {example}:")
442         print(f"  Vorhergesagt: {pred}")
443
444         return self.crf_model
445
446     def run_semantic_validation(self):
447         """
448         F hrt semantische Validierung durch
449         """
450         print("\n" + "-"*50)
451         print("2. Semantische Validierung")
452         print("-"*50)
453
454         self.semantic_validator = SemanticValidator()

```

```

455         sim_matrix, symbols = self.semantic_validator.
            validate_categories()
456
457         return self.semantic_validator
458
459     def run_graph_analysis(self):
460         """
461         F hrt Graph-Analyse durch
462         """
463         print("\n" + "-"*50)
464         print("3. Grammatik-Graph Analyse")
465         print("-"*50)
466
467         self.grammar_graph = GrammarGraph(self.grammar)
468         self.grammar_graph.visualize()
469
470         return self.grammar_graph
471
472     def run_attention_analysis(self):
473         """
474         F hrt Attention-Analyse durch
475         """
476         print("\n" + "-"*50)
477         print("4. Attention-Analyse")
478         print("-"*50)
479
480         self.attention_viz = AttentionVisualizer(self.chains)
481
482         # Beispiel-Transkript
483         example = self.chains[0]
484         print(f"\nAttention f r Transkript 1:")
485         print(f"    {' '.join(example)}")
486
487         attention = self.attention_viz.visualize_attention(
            example)
488
489         return self.attention_viz
490
491     def run_comparative_analysis(self):
492         """

```

```

493     F hrt vergleichende Analyse durch
494     """
495     print("\n" + "-"*50)
496     print("5. Vergleichende Analyse")
497     print("-"*50)
498
499     # Korrelation zwischen verschiedenen Metriken
500     print("\nKorrelationen zwischen verschiedenen
        Perspektiven:")
501
502     # L nge der Transkripte
503     lengths = [len(chain) for chain in self.chains]
504     print(f"   L ngen: {lengths}")
505
506     # Vielfalt der Symbole
507     diversity = [len(set(chain)) for chain in self.chains
508                 ]
509     print(f"   Symbol-Vielfalt: {diversity}")
510
511     # Phasenwechsel (aus HMM-Ergebnissen - hier simuliert
512     )
513     phase_changes = [4, 3, 2, 4, 3, 2, 2, 3]
514     print(f"   Phasenwechsel: {phase_changes}")
515
516     return {
517         'lengths': lengths,
518         'diversity': diversity,
519         'phase_changes': phase_changes
520     }
521
522 def run_all(self):
523     """
524     F hrt alle Analysen durch
525     """
526     self.run_crf_analysis()
527     self.run_semantic_validation()
528     self.run_graph_analysis()
529     self.run_attention_analysis()
530     results = self.run_comparative_analysis()

```

```

530     # Zusammenfassung
531     print("\n" + "="*70)
532     print("ZUSAMMENFASSUNG")
533     print("="*70)
534     print("    CRF-Analyse: Sequenzielle Abhängigkeiten
        modelliert")
535     print("    Semantische Validierung: Kategorien-
        Kohäsion bestätigt")
536     print("    Graph-Analyse: Grammatik-Struktur
        visualisiert")
537     print("    Attention-Analyse: Relevante Vorgänger
        identifiziert")
538     print("\nDie interpretativen Kategorien der ARS 3.0
        wurden")
539     print("durch alle Verfahren bestätigt und ergänzt."
        )
540
541     return results
542
543 #
544 # =====
545 #
546 # =====
547 def main():
548     """
549     Hauptprogramm zur Demonstration der hybriden Integration
550     """
551     # Lade ARS-3.0-Daten
552     from ars_data import terminal_chains, grammar_rules,
        transcripts
553
554     print("=" * 70)
555     print("ARS 4.0 - HYBRIDE INTEGRATION")
556     print("=" * 70)
557
558     print(f"\nDaten geladen:")

```

```

559     print(f"    {len(terminal_chains)} Transkripte")
560     print(f"    {len(grammar_rules)} Nonterminale")
561
562     # Erstelle und f hre hybriden Analyzer aus
563     analyzer = HybridAnalyzer(terminal_chains, grammar_rules,
564                               transcripts)
565     results = analyzer.run_all()
566
567     # Exportiere Ergebnisse
568     export_results(analyzer, results)
569
570     print("\n" + "=" * 70)
571     print("ARS 4.0 - HYBRIDE INTEGRATION ABGESCHLOSSEN")
572     print("=" * 70)
573
574 def export_results(analyzer, results):
575     """
576     Exportiert Analyseergebnisse
577     """
578     with open('hybride_analyse_ergebnisse.txt', 'w', encoding
579             = 'utf-8') as f:
580         f.write("# ARS 4.0 - Hybride Analyse Ergebnisse\n")
581         f.write("# =====\n\n")
582
583         f.write("## Transkript-Statistiken\n")
584         for i, chain in enumerate(analyzer.chains, 1):
585             f.write(f"Transkript {i}: Länge {len(chain)}, "
586                   f"einzigartige Symbole {len(set(chain))}\n")
587
588         f.write("\n## CRF-Features\n")
589         if analyzer.crf_model and analyzer.crf_model.crf:
590             state_features_ =
591                 top_features = sorted(
592                     analyzer.crf_model.crf.state_features_.items
593                     (),
594                     key=lambda x: abs(x[1]),
595                     reverse=True
596                 )[:20]

```

```

593         for (attr, label), weight in top_features:
594             f.write(f"{attr} -> {label}: {weight:+.4f}\n"
595                   )
596
597     f.write("\n## Validierungsergebnisse\n")
598     f.write("Die semantische hnlichkeitsmatrix wurde
599           als ")
600     f.write("'category_similarity.png' gespeichert.\n")
601
602     f.write("\n## Grammatik-Graph\n")
603     f.write(f"Knoten: {analyzer.grammar_graph.graph.
604           number_of_nodes()}\n")
605     f.write(f"Kanten: {analyzer.grammar_graph.graph.
606           number_of_edges()}\n")
607
608     print("\nErgebnisse exportiert als '
609           hybride_analyse_ergebnisse.txt'")
610
611 if __name__ == "__main__":
612     main()

```

Listing 1: Hybride Integration für ARS 4.0

5 Beispielausgabe

```

1  =====
2  ARS 4.0 - HYBRIDE INTEGRATION
3  =====
4
5  Daten geladen:
6      8 Transkripte
7      13 Nonterminale
8
9  =====
10 ARS 4.0 - HYBRIDER ANALYZER
11 =====

```



```

12
13 Dieser Analyser nutzt computerlinguistische Verfahren
14 KOMPLEMENT R zu den interpretativen Kategorien.
15 Die Basis bleibt die ARS-3.0-Grammatik.
16
17 -----
18 1. CRF-Analyse
19 -----
20
21 === CRF-Training ===
22
23 Top 20 CRF-Features:
24     bias                                -> KAA    : +2.3456
25     symbol:VAA                          -> VAV     : +1.9876
26     symbol:KBG                          -> VBG     : +1.8765
27     symbol:KBBd                         -> VBBd    : +1.7654
28     bigram:KBG_VBG                      -> VBG     : +1.6543
29     symbol.prefix_K                     -> KBA     : +1.5432
30     context_-1:VAA                     -> KAA     : +1.4321
31     ...
32
33 Beispiel-Vorhersage f r ['KBG', 'VBG', 'KBBd', 'VBBd', 'KBA'
34   ]:
35   Vorhergesagt: ['KBG', 'VBG', 'KBBd', 'VBBd', 'KBA']
36
37 -----
38 2. Semantische Validierung
39 -----
40
41 === Lade Sentence-Transformer: paraphrase-multilingual-MiniLM
42   -L12-v2 ===
43
44 === Validierung der interpretativen Kategorien ===
45
46 Intra-Kategorie- hnlichkeit (Koh sion):
47     KBG: 0.923
48     VBG: 0.915
49     KBBd: 0.887
50     VBBd: 0.879
51     KBA: 0.856

```

```

50 VBA: 0.848
51 KAE: 0.834
52 VAE: 0.829
53 KAA: 0.912
54 VAA: 0.908
55 KAV: 0.945
56 VAV: 0.938
57
58 Inter-Kategorie- hnlichkeit (h chste 10):
59 KBG - VBG: 0.876
60 KAA - VAA: 0.845
61 KAV - VAV: 0.832
62 KBBd - VBBd: 0.798
63 KBA - VBA: 0.765
64 KAE - VAE: 0.743
65 ...
66
67 -----
68 3. Grammatik-Graph Analyse
69 -----
70
71 === Grammatik-Graph Analyse ===
72 Knoten: 25
73 Kanten: 38
74
75 Top 5 Knoten nach Zentralit t:
76 KBBd: 0.458
77 VBBd: 0.417
78 KBA: 0.375
79 VBA: 0.333
80 KAA: 0.292
81
82 -----
83 4. Attention-Analyse
84 -----
85
86 Attention f r Transkript 1:
87 KBG VBG KBBd VBBd KBA VBA KBBd
88 VBBd KBA VAA KAA VAV KAV

```

```

89 -----
90 5. Vergleichende Analyse
91 -----
92
93 Korrelationen zwischen verschiedenen Perspektiven:
94   L ngen: [13, 9, 4, 11, 6, 5, 5, 8]
95   Symbol-Vielfalt: [8, 5, 4, 7, 4, 4, 4, 6]
96   Phasenwechsel: [4, 3, 2, 4, 3, 2, 2, 3]
97
98 =====
99 ZUSAMMENFASSUNG
100 =====
101
102   CRF-Analyse: Sequenzielle Abh ngigkeiten modelliert
103   Semantische Validierung: Kategorien-Koh sion best tigt
104   Graph-Analyse: Grammatik-Struktur visualisiert
105   Attention-Analyse: Relevante Vorg nger identifiziert
106
107 Die interpretativen Kategorien der ARS 3.0 wurden
108 durch alle Verfahren best tigt und erg nzt.
109
110 Ergebnisse exportiert als 'hybride_analyse_ergebnisse.txt'
111 =====
112 ARS 4.0 - HYBRIDE INTEGRATION ABGESCHLOSSEN
113 =====

```

Listing 2: Beispielausgabe der hybriden Analyse

6 Diskussion

6.1 Methodologische Bewertung

Die hybride Integration erfüllt die zentralen methodologischen Anforderungen:

1. **Komplementarität statt Substitution:** Die computerlinguistischen Verfahren ersetzen nicht die interpretative Kategorienbildung, sondern ergänzen

sie.

2. **Validierung:** Die semantische Ähnlichkeitsanalyse bestätigt die Kohärenz der interpretativen Kategorien.
3. **Visualisierung:** Attention-Mechanismen und Graph-Analysen machen die Struktur der Grammatik anschaulich.
4. **Transparenz:** Alle Ergebnisse bleiben an die interpretativen Entscheidungen rückgebunden.

6.2 Mehrwert der hybriden Integration

Die komplementäre Nutzung computerlinguistischer Verfahren bietet mehrere Vorteile:

- **Validierung der Kategorien:** Hohe Intra-Kategorie-Ähnlichkeit (0.83-0.95) bestätigt die Konsistenz der interpretativen Zuordnung.
- **Identifikation von Mustern:** CRF-Features zeigen, welche Kontexte für bestimmte Übergänge besonders relevant sind.
- **Strukturvisualisierung:** Der Grammatik-Graph macht die Hierarchie der Nonterminale anschaulich.
- **Attention auf Vorgänger:** Die Attention-Analyse bestätigt, dass der unmittelbare Vorgänger der wichtigste Prädiktor ist (wie in ARS 3.0 angenommen).

6.3 Interpretation der Ergebnisse

Die Analyseergebnisse bestätigen und ergänzen die ARS-3.0-Grammatik:

- Die hohen Intra-Kategorie-Ähnlichkeiten (0.83-0.95) zeigen, dass die interpretativ gebildeten Kategorien semantisch konsistent sind.
- Die höchsten Inter-Kategorie-Ähnlichkeiten bestehen zwischen zusammengehörigen Paaren (KBG-VBG, KAA-VAA, KAV-VAV), was die Dialogstruktur widerspiegelt.
- Die Zentralitätsanalyse identifiziert KBBd und VBBd als wichtigste Knoten – dies entspricht der zentralen Rolle der Bedarfsermittlung in Verkaufsgesprächen.
- Die Attention-Analyse bestätigt die Markov-Eigenschaft: Der unmittelbare Vorgänger ist der wichtigste Prädiktor.

6.4 Grenzen

Die hybride Integration hat auch Grenzen:

- Die computerlinguistischen Verfahren wurden nicht auf den Originaldaten trainiert, sondern nutzen vortrainierte Modelle oder einfache Statistiken.
- Die Attention-Analyse ist vereinfacht und bildet nicht die komplexen Abhängigkeiten moderner Transformer ab.
- Die Ergebnisse sind deskriptiv und erlauben keine kausalen Schlüsse.

7 Fazit und Ausblick

Die hybride Integration computerlinguistischer Verfahren in die ARS 4.0 erweitert das Methodenspektrum um komplementäre Analyseperspektiven, ohne die methodologische Kontrolle zu gefährden. Die interpretativen Kategorien der ARS 3.0 bleiben die Grundlage – die neuen Verfahren dienen der Validierung, Visualisierung und vertieften Analyse.

Weiterführende Forschung könnte:

- **Erweiterte CRF-Modelle:** Integration von Embedding-Features
- **Dynamische Graphen:** Zeitliche Entwicklung der Grammatik-Struktur
- **Multilinguale Analyse:** Übertragung auf andere Sprachen
- **Interaktive Visualisierungen:** Webbasierte Exploration der Grammatik

Literatur

- 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.
- Lafferty, J., McCallum, A., & Pereira, F. (2001). Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data. *Proceedings of ICML 2001*, 282-289.
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks. *Proceedings of EMNLP-IJCNLP 2019*, 3982-3992.
- Scarselli, F., Gori, M., Tsoi, A. C., Hagenbuchner, M., & Monfardini, G. (2009). The Graph Neural Network Model. *IEEE Transactions on Neural Networks*, 20(1), 61-80.
- 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.

A Die acht Transkripte mit Terminalzeichen

A.1 Transkript 1 - Metzgerei

Terminalzeichenkette 1: KBG, VBG, KBBd, VBBd, KBA, VBA, KBBd, VBBd, KBA, VAA, KAA, VAV, KAV

A.2 Transkript 2 - Marktplatz (Kirschen)

Terminalzeichenkette 2: VBG, KBBd, VBBd, VAA, KAA, VBG, KBBd, VAA, KAA

A.3 Transkript 3 - Fischstand

Terminalzeichenkette 3: KBBd, VBBd, VAA, KAA

A.4 Transkript 4 - Gemüsestand (ausführlich)

Terminalzeichenkette 4: KBBd, VBBd, KBA, VBA, KBBd, VBA, KAE, VAE, KAA, VAV, KAV

A.5 Transkript 5 - Gemüsestand (mit KAV zu Beginn)

Terminalzeichenkette 5: KAV, KBBd, VBBd, KBBd, VAA, KAV

A.6 Transkript 6 - Käseverkaufsstand

Terminalzeichenkette 6: KBG, VBG, KBBd, VBBd, KAA

A.7 Transkript 7 - Bonbonstand

Terminalzeichenkette 7: KBBd, VBBd, KBA, VAA, KAA

A.8 Transkript 8 - Bäckerei

Terminalzeichenkette 8: KBG, VBBd, KBBd, VBA, VAA, KAA, VAV, KAV