
Spis treści

Przedmowa	13
Informacja o finansowaniu prac	15
Podziękowania	17
1. Założenia badawcze	19
1.1. Referencja, koreferencja, anafora, asocjacja	19
1.2. Motywacja	21
1.3. Cele badawcze	22
1.4. Zakres badań	23
1.5. Metodologia	24
2. Od ujęć teoretycznych do dekodowania relacji referencyjnych	27
2.1. Pojęcie i zakres referencji	27
2.2. Klasyfikacje typów wzmianek i relacji referencyjnych	29
2.2.1. Klemensiewicz	30
2.2.2. Topolińska	31
2.2.3. Paduczewa	32
2.2.4. Clark i inne klasyfikacje zagraniczne	33
2.3. Cechy relacji referencyjnych	35
2.4. Projekty korpusowe	38
2.5. Komputerowe implementacje modelu referencji	41
2.6. Metody ewaluacji	48
2.6.1. Miara MUC	50
2.6.2. Miara B ³	51
2.6.3. Miara CEAF	52
2.6.4. Miara BLANC	53
3. Model relacji referencyjnych	55
3.1. Świat tekstu i własność referencji	55
3.2. Typy i granice wzmianek	56

3.3. Relacje tekstowe i pozatekstowe	58
3.4. Typologia referencyjna	59
3.4.1. Koreferencja	61
3.4.2. Referencja pośrednia	61
3.4.3. Relacje wspierające	63
3.4.4. Relacje wykluczające	63
3.4.5. Aspekty	64
4. Korpus zależności referencyjnych	67
4.1. Wybór tekstów	67
4.2. Wybór strategii anotacyjnej	69
4.2.1. Liczba i profil anotatorów	69
4.2.2. Anotacja szeregową a anotacja równoległa	71
4.2.3. Preanotacja	72
4.2.4. Superanotacja automatyczna	73
4.3. Prace anotacyjne	75
4.3.1. Faza rozpoznawcza	75
4.3.2. Anotacja koreferencji nominalnej	76
4.3.3. Anotacja ogólnych zależności referencyjnych	78
4.4. Narzędzia anotacyjne	79
4.5. Zgodność anotatorów	83
4.5.1. Wzmianki	83
4.5.2. Klastry koreferencyjne	84
4.5.3. Pozostałe relacje	85
4.6. Korekta błędów	87
4.7. Udostępnienie korpusu	88
4.7.1. Format SemEval/CoNLL	89
4.7.2. Format MMAX	91
4.7.3. Format TEI	94
4.7.4. Format narzędzia BRAT i wersja online korpusu	96
4.7.5. Wyszukiwarka korpusowa	101
4.8. Statystyki korpusowe	101
4.8.1. Własności tekstów	101
4.8.2. Własności wzmianek	103
4.8.3. Statystyka relacji referencyjnych	107

5. Implementacja	113
5.1. Wykrywanie wzmianek	113
5.1.1. System regułowy	114
5.1.2. System statystyczny	115
5.2. Wykrywanie koreferencji	117
5.2.1. System regułowy	117
5.2.2. System statystyczny	118
5.2.3. System sitowy	120
5.2.4. System neuronowy	122
5.2.5. System hybrydowy	125
5.3. Dekodowanie relacji pośrednich i pomocniczych	125
6. Ewaluacja szczegółowa	127
6.1. Wykrywanie wzmianek	127
6.2. Wykrywanie koreferencji	128
6.2.1. Wzmianki idealne	128
6.2.2. Wzmianki systemowe	129
6.3. Wykrywanie wybranych zależności pośrednich i pomocniczych	130
6.4. Analiza błędów	130
6.4.1. Błędy wykrywania wzmianek	133
6.4.2. Błędy wykrywania koreferencji	135
6.4.3. Analiza relacji pośrednich	136
7. Perspektywy badań	139
7.1. W stronę koreferencji uniwersalnej	139
7.2. Model Penn Discourse Treebank	142
7.3. Anotacja metatekstowa	146
Podsumowanie	149
English summary	153
Bibliografia	161
Skorowidz	187
Skorowidz terminów angielskich	189
Wykaz powstałych narzędzi i zasobów	191

Table of contents

Preface	13
Funding information	15
Acknowledgements	17
1. The point of departure	19
1.1. Reference, coreference, anaphora, association	19
1.2. Motivation	21
1.3. Research objectives	22
1.4. Scope of work	23
1.5. Methodology	24
2. From theoretical perspective to decoding of referential relations	27
2.1. The concept and scope of reference	27
2.2. Classifications of mention types and referential relations	29
2.2.1. Klemensiewicz	30
2.2.2. Topolińska	31
2.2.3. Paduczewa	32
2.2.4. Clark and other foreign classifications	33
2.3. Features of referential relations	35
2.4. Corpus projects and automated resolution	38
2.5. Computer-based implementations of reference	41
2.6. Evaluation methods	48
2.6.1. MUC metric	50
2.6.2. B ³ metric	51
2.6.3. CEAF metric	52
2.6.4. BLANC metric	53
3. Typology of referential relations	55
3.1. Discourse world and referential properties	55
3.2. Mention types and borders	56

3.3. Textual relations vs. out-of-text reference	58
3.4. Referential typology	59
3.4.1. Coreference	61
3.4.2. Indirect reference	61
3.4.3. Supporting relations	63
3.4.4. Excluding relations	63
3.4.5. Facets	64
4. Corpus of referential relations	67
4.1. Text selection	67
4.2. Annotation strategy	69
4.2.1. Number and profile of annotators	69
4.2.2. Serial vs. parallel annotation	71
4.2.3. Pre-annotation	72
4.2.4. Automated adjudication	73
4.3. Annotation phases	75
4.3.1. Preparatory phase	75
4.3.2. Annotation of nominal coreference	76
4.3.3. Annotation of referential relations	78
4.4. Annotation tools	79
4.5. Annotator agreement	83
4.5.1. Mentions	83
4.5.2. Coreference clusters	84
4.5.3. Other relations	85
4.6. Error correction	87
4.7. Corpus availability	88
4.7.1. SemEval/CoNLL format	89
4.7.2. MMAX format	91
4.7.3. TEI format	94
4.7.4. BRAT format and online corpus version	96
4.7.5. Corpus search engine	101
4.8. Corpus statistics	101
4.8.1. Textual properties	101
4.8.2. Mention statistics	103
4.8.3. Coreference clusters	107

5. Implementation	113
5.1. Mention detection	113
5.1.1. Rule-based mention detection	114
5.1.2. Statistical mention detection	115
5.2. Coreference resolution	117
5.2.1. Rule-based coreference resolution	117
5.2.2. Statistical coreference resolution	118
5.2.3. Sieve-based coreference resolution	120
5.2.4. Deep network-based coreference resolution	122
5.2.5. Hybrid system	125
5.3. Decoding associative and auxiliary relations	125
6. Evaluation	127
6.1. Mention detection	127
6.2. Coreference resolution	128
6.2.1. Gold mentions	128
6.2.2. System mentions	129
6.3. Detection of selected indirect relations	130
6.4. Error analysis	130
6.4.1. Mention detection errors	133
6.4.2. Coreference resolution errors	135
6.4.3. Analysis of bridging relations	136
7. Research perspectives	139
7.1. Towards Universal Coreference	139
7.2. Penn Discourse Treebank model	142
7.3. Discourse-based annotation	146
Conclusions	149
English summary	153
Bibliography	161
Glossary	187
Glossary of English terms	189
Implemented tools and resources	191