

# CRF를 이용한 대명사 참조해소 시스템

김형철<sup>○</sup>, 서형원, 김재훈, 최윤수

한국해양대학교 / 한국과학기술정보연구원

yhdosu@nate.com, wonn24@gmail.com, jhoon@hhu.ac.kr, armian@kisti.re.kr

## Automated Pronoun Resolution Using CRF

Hyung-Chul Kim<sup>○</sup>, Hyung-Won Seo, Jae-Hoon Kim, Yun-Soo Choi

Korea Maritime University / Korea Institute of Science and Technology Information

### 요 약

이 논문은 영어 문장에서 대명사의 참조해소 시스템을 구현한다. 대명사는 문장에서 반복되는 말 대신에 사용하는 단어이다. 반복되는 말을 선행어라고 하며 대명사는 선행어보다 간결한 형식으로 사용된다. 정보 검색이나 정보추출에서 대명사를 그대로 색인하여 검색하면 정확한 정보를 추출할 수 없다. 따라서 대용어가 가리키는 개체를 정확히 파악해서 이 정보를 색인하고 검색하면 정보검색, 정보추출, 질의응답의 성능을 크게 개선할 수 있다. 이 논문에서는 CRF모델을 이용해서 이용하여 영어 문서에서 대명사 참조해결 방법을 제안하고 이를 구현한다.

주제어: 참조해소, CRF

### 1. 서 론

가상 공간(cyber space)라고 하는 웹은 전 세계를 통하여 많은 정보를 쉽게 얻을 수 있는 정보의 보고이다. 가상 공간에 존재하는 정보들은 매우 다양하며, 그 양 또한 매우 빠른 속도로 증가하고 있다. 방대한 정보공간에서 유용한 정보를 효과적으로 찾기 위해 정보검색이나 정보추출 등이 널리 사용된다. 이러한 기법들은 자연언어 처리를 기반으로 하여 사용자가 필요로 하는 정보들을 인식하여 요약된 형태로 가공하거나 서로의 관계들을 규명한다. 그러한 작업들은 아직도 많은 해결되지 않은 문제들을 가지고 있고, 큰 문제 중 하나가 대용어(anaphora) 참조해소이다[1].

대용어는 대용의 기능을 담당하는 어휘로서 선행어(antecedent)보다 간결한 형식을 사용하여 반복되는 성분을 대신하는 것으로 명확한 진술을 피하거나 정확한 단어를 떠올릴 수 없을 때 사용하는 말이며, 대명사(pronoun)가 그 대표적인 예이다. 문장의 의미를 정확히 파악하기 위해서는 문장에서 사용된 대용어가 이전 문장 혹은 대화의 어떤 사물이나 행위를 가리키는지를 구별하는 과정을 참조해소(reference resolution)라고 한다[2]. 예를 들어 한 문서 안에서 “이명박”이 “Lee Myung Bak”, “Mr. Lee”, “Korea President”, “He” 등으로 표현되었을 때 이들이 모두 같은 개체임을 찾아내는 것을 말한다. 대명사 참조해소 특별히 대용어가 대명사일 경우를 말한다. 앞에서 언급했지만 이러한 대용어 처리는 정보검색이나 정보추출의 성능에 크게 영향을 미친다[3,4]. 정보 추출에서 대용어를 그대로 색인하여 검색하면 정확한 정보를 추출할 수 없으며 검색하고 싶은 내용들이 대용어의 형태로 출력되면 사용자들 또한 정확한 내용을 확인할 수 없게 된다. 따라서 대용어가 가리키는 개체를 정확히 파악해서 이 정보를 색인하고 검색하면 정보검색, 정보추출, 질의응답 시스템들의 성능을 크게 개선할 수 있다. 대용어 처리에 대한 연구는 꽤 오랜 역

사를 가지고 있으나 실용화된 시스템을 사용하는 경우는 거의 없다고 해도 과언이 아니다. 예전에는 중심화 이론(centering theory) 등을 중심으로 규칙기반의 연구[5, 6]나 경험규칙의 연구[7]이 주로 진행 되었으나 최근에 와서는 기계학습을 이용한 대용어 처리에 관한 연구[8, 9]도 활발히 진행되고 있다. 하지만 그러한 연구들의 성능을 그다지 좋은 편은 아니다.

이 논문에서는 기계학습 방법을 이용하여 대용어 중 대명사를 대상으로 참조해소 시스템을 구현한다 2장에서는 관련연구를 살펴본다 3장에서 CRF를 이용한 참조해소 모델을 제안하고 4장에서는 제안된 모델의 성능을 평가하여 그 유용성을 살펴본다. 끝으로 5장에서는 향후 연구 과제에 대해 생각해 보고 결론을 맺고자 한다

### 2. 관련 연구

#### 2.1 CRF(Conditional Random Field)

HMM은 관찰열의 확률과 정답 태그열의 순서를 이용한 확률의 결합 확률을 이용한 생성 모델이다 품사 부착의 경우 입력단어에 대한 확률과 품사열 순서, 하지만 이러한 모델의 특성상 두 가지의 큰 문제점이 발생한다 첫 번째는 다중의 서로 다른 자질들을 사용하기가 매우 어렵다는 것이다. 다중의 자질을 사용하고자 하면 그 자질들을 조합하여 하나의 자질로 통합하여야 한다. 하지만 이렇게 하더라도 자질들의 종류가 늘어날 때마다 통합된 자질의 클래스가 크게 늘어나게 되고 계산 속도에 큰 문제를 가져오게 된다. 두 번째 문제는 품사열의 순서를 이용할 때 범위에 대한 제약이다.

이러한 문제를 해결하기 위해 Conditional Model이 적용된 MEMM(maximum entropy Markov model)이 개발되었다. MEMM는 기존의 두 가지 문제를 해결하면서 대부분의 경우에 HMM보다 높은 성능을 보장하였지만, 유한 상태 모델을 사용함으로써 Label Bias 문제를 가지

게 되었다. 최근에는 label bias 문제를 해결하면서 MEMM 이상의 성능을 보장하는 CRF 모델이 개발되어 널리 사용되고 있다[5].

CRF는 품사 부착과 같은 연속적인 자료의 라벨(label)을 결정하는데 매우 유용하게 사용되는 분별 확률 모델(discriminative probability model)이며(식 (1)), 즉 주어진 입력 벡터  $\mathbf{x}$ 에 대해서 조건부 확률  $p(\mathbf{y}|\mathbf{x})$ 를 최대로 하는 라벨  $\mathbf{y}^*$ 를 선택하는 비방향성 그래프 모델이다[5].

$$\mathbf{y}^* = \operatorname{argmax}_{\mathbf{y}} p(\mathbf{y}|\mathbf{x}) \quad (1)$$

여기서  $p(\mathbf{y}|\mathbf{x})$ 는 CRF의 종류에 따라 다양하게 정의될 수 있다. 품사 부착의 경우에는 선형연쇄(linear chain) 모델이 적합하며 식 (2)과 같이 구한다.

$$p(\mathbf{y}|\mathbf{x}) = \frac{1}{Z(\mathbf{x})} \exp\left(\sum_{k=1}^K \lambda_k f_k(y_t, y_{t-1}, \mathbf{x}_t)\right) \quad (2)$$

여기서  $f_k(\cdot)$ 는 자질 함수(feature function)이며 자질  $k$ 에 따른 특성 함수(characteristic function)이다. 즉 주어진 입력  $y_{t-1}, y_t, \mathbf{x}$ 에 자질  $k$ 가 포함되어 있으면 1을 반환하고 그렇지 않으면 0을 반환한다.  $\lambda_k$ 는 매개변수이며 자질  $k$ 의 가중치가 된다.  $\lambda_k$ 의 학습 방법은 일반적으로 기울기 하강 알고리즘(gradient descent algorithm: Generalized Iterative Scaling(GIS), Improved Iterative Scaling(IIS))과 준뉴턴 방법(quasi-Newton method: limited memory BFGS(L-BFGS))를 주로 사용한다.  $Z(\mathbf{x})$ 는 정규화 요소이다.

## 2.2 기존의 참조해소 방법

앞에서 간략히 언급했듯이 대용어 참조해소 방법으로 는 규칙기반에 의한 방법[5-7]과 기계학습에 의한 방법[8,9] 등이 있다. 규칙기반에 의한 방법은 대용어에 대하여 대용어 후보들을 수집하여 성(gender), 수(number) 등의 제약조건을 만족하는 후보들 중에서 경험적으로 가능성이 높은 후보를 선택하는 것이다. 대표적인 것으로 1994년에 Lapain과 Leass가 제안한 RAP(Resolution of Anaphora Procedure)가 있다. RAP의 경우 제약조건에 만족하는 후보들 중 구의 속성이나 위치 문장 거리 등에 대해 상이한 가중치를 할당하여 가장 높은 점수를 획득한 후보를 선택하는 시스템이다[7]. 하지만 규칙기반 시스템의 경우 여러 유형의 대용어 관계를 규칙화하는 것이 쉽지 않다는 점에서 많은 제약이 있었다.

기계학습 방법은 학습 말뭉치로부터 대용어 관계를 결정하는 규칙을 학습하는 접근 방법이다. 대용어와 대용어가 태깅된 학습말뭉치로부터 유용한 자질들을 선택하고 추출하여, 모델을 학습한다. 학습된 모델을 만드는 방법은 크게 두 가지로 나뉘어진다. 첫 번째 방법은 대용어와 선행어 후보가 대용어 관계에 속하는지를 결정하는 분류 방법(binary classification)[8,11]이다. 두 번째 방법은 선행어 후보들에 대해서 점수를 계산하고 그 점수에 따라 선행어 후보들의 순위화하여 가장 높은 순위에 있는 후보를 선택하는 순위화 방법(ranking model)[7]이다. 기계학습 방법을 이용한 방법을 좀더 살펴보자

[12]은 SVM을 이용한 터키어의 참조해소 시스템을 제안했으며 약 73%의 정확도를 보였다. [13]는 순위화 모델을 제안하였고, 영어에 대하여 약 72.4%의 정확도를 보였다. [14]은 GENIA 말뭉치[10]에 대하여 최대 엔트로피 모델을 이용해서 약 71.43%의 정확도를 보였다.

## 3. CRF를 이용한 참조해소 모델

### 3.1. 대명사 참조해소 시스템

이 논문에서는 CRF를 이용한 대명사 참조해소 시스템을 제안한다. 제안된 시스템은 크게 두 부분으로 구성된다. 하나는 대용어로서 대명사를 인식하는 시스템이고 다른 하나는 인식된 대명사의 선행어를 찾는 시스템이다. 전자를 대용어 인식 시스템(anaphoric pronoun identifier)이라고 하고 후자를 선행어 결정 시스템(pronoun resolver)이라고 한다. 품사가 대명사(PRP)라고 해서 모두 대용어는 아니다 즉 문서 내에 어떤 선행어를 가리키지 않는 대명사가 존재한다는 것이다 예를 들면 문장 “It is important not to give up”에서 ‘It’은 선행어를 가지지 않는 대명사이다 대용어 인식 시스템은 품사가 대명사(PRP)인 단어 중에서 대용어를 찾아내는 시스템이다. 이 논문에서는 이를 위해서 3장에서 기술될 여러 가지 자질 집합을 구해서 CRF 모델을 이용한 분류 모델을 구현하여 대용어 인식 시스템으로 사용한다. 대용어 인식 시스템에 의해서 인식된 대용대명사(anaphoric pronoun)를 대상을 선행어를 결정하는 시스템이 선행어 결정 시스템이다 아래의 예문에서 2개의 대용대명사 ‘them’과 ‘it’이 있으며 각각의 선행어는 ‘Those figure’와 ‘the government’이다.

<E id=1 Those figures> are almost exactly what the government proposed to legislators in September. If <E id=2 the government> can stick with <E id=1 them>, <E id=1 it> will be able to halve this year’s 120 billion ruble (US \$193 billion) deficit.

### 3.2 대명사 참조해소를 위한 자질 선택

기계학습 방법을 사용할 때 성능에 큰 영향을 미치는 요소 중 하나는 자질 집합이다. 이 절에서는 대명사 참조해소를 위한 자질 집합에 대해서 기술한다 대용대명사를 결정하기 위해서 대용대명사 자신과 주변의 어휘 자체 정보와 품사열 정보를 사용할 수 있으며 여러 번의 실험을 통해서 <표 1>과 같은 자질 집합을 이 논문에서는 사용한다.

<표 1> 대용어 인식 시스템의 자질 집합

종류	자질 집합
어휘	$w_{i-2}, w_{i-1}, w_i, w_{i+1}, w_{i+2},$
	$w_{i-1}w_i, w_iw_{i+1}$
품사	$t_{i-2}, t_{i-1}, t_i, t_{i+1}, t_{i+2},$
	$t_{i-1}t_i, t_it_{i+1}$
	$t_{i-2}t_{i-1}t_i, t_{i-1}t_it_{i+1}, t_it_{i+1}t_{i+2}$

1) <http://www-tsujii.is.s.u-tokyo.ac.jp/~genia/topics/Corpus>

<표 1>에서  $w_i$ 는 대용대명사이고  $t_i$ 는 대용대명사의 품사이다. 색인이 음수이면  $w_i$ 의 이전 단어이고 양수이면 다음 단어이다.

<표 2> 선행어 결정 시스템의 자질 집합

종류	자질
대명사	- 인칭대명사 인지 아닌지 - 소유격 인지 아닌지 - 3인칭 인지 아닌지 - 재귀대명사 인지 아닌지 - 대문자를 포함 했는지 아닌지 - 앞 / 뒤 단어의 품사 - 앞뒤 단어를 포함한 품사열 5개 )
후보	- 구성 단어의 수 - 대명사 인지 아닌지 - Is indefinite NP - Is Demonstrative NP - 앞 / 뒤 단어의 품사 - 자신의 품사 - 이전의 텍스트에서 자신이 나온 횟수
관계	- 대명사와 후보간의 문장 거리 - 대명사와 후보간의 단어 거리

선행어 결정 시스템에 사용되는 자질 집합은 크게 세 가지로 분류한다. 대용대명사에 대한 자질 선행어에 대한 자질, 대용대명사와 선행어 사이의 관계 자질이 그것이다. 각각에 대해 품사나 격, 위치 정보 등을 조합하여 자질들을 생성하게 된다. 하지만 자질들의 수가 너무 많고, 기계학습의 학습 속도 문제로 인해 이러한 자질의 모든 조합에 대해 실험하는 것은 사실상 불가능하다 그래서 기존의 연구8, 9, 12, 13]들을 참고하여 사용할 수 있는 자질들의 리스트를 작성하고 결정 트리에서 사용되는 정보 이득(information gain)[6]을 이용하여 선행어 결정 시스템을 위한 자질 집합을 결정하였다(표 2).

### 3.3 선행어 결정 방법

이 절에서는 선행어 결정 시스템에서 선행어 결정 방법에 대해 자세히 설명한다. 이 시스템은 [9]에서 제안한 TCM(twin-candidate model)을 사용하여 승자진출전(tournament) 방법을 사용한다. TCM은 대용대명사와 각각의 후보 선행어들 사이의 관계에 의해서 최종 선행어를 결정하는 것이 아니라 두 후보 선행어들끼리 경쟁할 수 있도록 모델링된 것이다. TCM에 의해서 모델이 되면 최종적으로 선행어를 결정하기 위해서는 모든 후보들 중 가장 먼저 2개의 후보를 선택하고 경쟁을 붙이게 된다. 이 경쟁에서 살아남은 후보와 아직 선택되지 않은 후보 중 1개를 선택하여 다시 경쟁하는 형태이다. 모든 후보들이 선택되어 남아있는 후보가 없다면 경쟁은 끝이 나고 최후에 살아남아 있는 후보가 정답으로 결정되는 시스템이다. 경쟁에 대한 정답 태그는 총 3가지로

“00”, “10”, “01” 이 그것이다. “00”은 둘다 정답이 아닌 경우이고 “10”은 앞의 것이, “01”은 뒤에 것이 경쟁에서 살아남은 것을 표시하는 태그이다. <표 3>은 실제 경쟁하는 예를 나타내었다.

<표 3> 승자진출전을 통한 선행어 결정

대명사	후보들	정답
[6 them]	[1 Those figures], [2 the government]	10
	[1 Those figures], [3 legislators]	10
	[1 Those figures], [4 September]	10
	[1 <b>Those figures</b> ], [5 the government]	10
[7 it]	[1 Those figures], [2 the government]	01
	[2 the government], [3 legislators]	10
	[2 the government], [4 September]	10
	[2 the government], [5 the government]	01
	[5 <b>the government</b> ], [6 them]	10

## 4. 실험 및 평가

### 4.1 말뭉치

이 논문에서는 기계학습을 위해 사용되는 말뭉치는 OntoNote<sup>2)</sup>이다. 이 말뭉치는 대용어의 참조 정보뿐 아니라 개체명(named entity), 품사, 기저구 정보가 포함되어 특별한 언어처리 시스템을 사용하지 않고도 참조해소 시스템을 구현할 수 있다. 이 논문에서는 OntoNote2의 WSJ을 사용한다. 이 말뭉치는 Penn Treebank<sup>3)</sup>에 포함된 WSJ의 문장에 대해서 대용어의 참조 정보를 포함하고 있다.

OntoNote2 - WSJ는 총 14,246개의 문장(308,736 단어)로 구성되어 있다. 앞에서 언급한 대로 이 말뭉치 하나만으로는 선행어 결정 시스템에서 필요한 모든 자질을 추출할 수 없기 때문에 Penn Treebank와 통합하여 문장 분리, 토큰 분리, 품사, 기저구, 개체명의 정보를 포함하는 새로운 형태의 말뭉치로 가공하였다. 이 중 90%를 학습 말뭉치(13,235 문장 / 309,541 단어)로, 10%를 실험 말뭉치(1,502 문장 / 34,363 단어)로 나누어 각각 학습 및 실험을 수행하였다.

### 4.2 성능 척도

대용어 인식 시스템에서는 문서에 포함된 대명사 중 대용대명사를 정확하게 찾는 비율을 성능 척도로 삼으며 이를 대용어 인식 정확률  $A_p$ 이라고 한다. 여기서  $n_p$ 는

2) <http://www ldc.upenn.edu/>

3) [www cis.upenn.edu/~treebank/](http://www cis.upenn.edu/~treebank/)

전체 문서에 포함된 모든 대명사의 수이고  $n_p^c$ 는 대명사들 중에서 정확하게 찾아낸 대용대명사의 수이다

$$A_p = \frac{n_p^c}{n_p} \times 100$$

선행어 결정 시스템에서는 대용대명사가 가리키는 선행어를 정확하게 찾는 비율을 성능 척도로 사용하며 이를 선행어 결정 정확률  $A_a$ 이라고 한다. 여기서  $n_a$ 는 전체 문서에 포함된 대용대명사의 수이고  $n_a^c$ 는 대용대명사들 중에서 선행어를 정확하게 찾아낸 대용대명사의 수이다.

$$A_a = \frac{n_a^c}{n_a} \times 100$$

### 4.3 성능 평가

<표 4>는 제안된 대용어 인식 시스템에 대한 성능 평가 결과이다. 실험 말뭉치에서 대명사가 차지하는 비율을 약 2.7%이며 이 중에서 대용대명사의 비율은 73%이다. 즉 대명사 중에서 모두 대용대명사로 분류할 경우에 73%의 정확률을 보인다. 제안된 자질 집합을 이용해서 대용어를 인식할 경우 그 정확률은 약 75%정도이다. 이는 아직 개선할 여지가 많이 남아 있음을 말해주고 있다. 자질 집합으로 단순히 단어와 품사 정보만 이용한다면 앞으로 WordNet이나 다양한 의미 정보가 사용된다면 좀 더 좋은 결과를 얻을 수 있을 것으로 기대된다.

<표 4> 실험말뭉치 및 대용어 인식 정확률

전체 단어 수	34,363
대명사 수 (P)	926
대명사 점유율	926 / 34363 = 2.7%
대용대명사 수(A)	676
대용대명사의 비율	676 / 926 = 73.0%
대용어 인식 시스템의 정답 수	696
<b>대용어 인식 정확률</b>	<b>696 / 926 = 75.16%</b>

<표 5>는 대용어 인식 시스템의 오류 결과를 분석하여 혼동 행렬(confusion matrix)이다. 이 시스템은 대용대명사를 대명사로 오인하는 비율이 대명사를 대용대명사로 오인하는 비율보다 훨씬 더 높다. 또한 이 시스템은 대명사를 대명사로 인식하는 것보다 대용대명사로 인식하는 비율이 훨씬 높다. 이는 학습말뭉치에서도 실험 말뭉치와 비슷한 비율(6651/8985=74%)로 차지하므로 학습된 시스템이 가능하면 대용대명사로 인식하려는 경향을 보인다. 앞으로 성능을 개선하기 위해서는 이를 분별하기 위한 여러 가지 자질에 대한 연구가 지속적으로 진행되어야 할 것이다.

<표 5> 대용어 인식 시스템에 대한 혼동 행렬

		정답	
		대명사	대용대명사
시스템	대명사	86	<b>164</b>
	대용대명사	<b>66</b>	610

<표 6>은 선행어 결정 시스템에 대한 성능 평가 결과이다. 이 시스템을 평가하기 위해서 대용대명사를 정확하게 인식된 것으로 가정한다. 전체 인식률은 약 83%로 [9]의 77%보다 좋은 결과를 보였다.

<표 5>선행어 결정의 정확률

대용대명사의 수	선행어를 정확하게 인식한 대용대명사의 수	정확도 (%)
676	526	83.13

## 5. 결론 및 향후 연구

이 논문에서는 대명사 참조해소 문제를 해결하기 위하여 기계학습을 이용한 모델을 제안하였다 제안된 모델은 현재 가장 성능이 좋다고 알려진 CRF를 이용하였으며 TCM 모델을 이용하여 승자진출전(tournament) 방식으로 최종 선행어를 결정하였다 전체 시스템은 대용어 인식 시스템과 선행어 결정 시스템으로 나뉘어진다 각 시스템은 아직 초기 연구 단계로서 다양한 분야에서 성능 개선을 여지를 가지고 있다. 정확률을 개선하기 위한 방법으로 말뭉치를 확장하는 방법이 있겠지만 대용어 결정 시스템으로 경우에는 좀더 다양한 문법 및 의미 자질이 사용되어야 할 것으로 판단된다. 예를 들면 수(number), 성(gender) 등 다양한 문법 자질과 각 단어의 WordNet 상의 의미 속성 등 다양한 의미 자질을 고려해야 할 것으로 판단된다.

### 감사의 글

본 연구는 한국과학기술정보연구원에서 수행하는 교육과학기술부 차세대 정보유통 핵심기술 연구개발 사업의 위탁연구로 수행되었습니다.

### 참고 문헌

- [1] C. Giuliano, A. Exploiting shallow linguistic information for relation extraction from biomedical literature, Proceedings of the 11th Conference of the European Chapter of the Association for Computational Linguistics, pp. 401-408, 2006.
- [2] D. Jurafsky and J. H. Martin, Speech and Language Processing, Prentice-Hall, 2009.
- [3] J. L. Vicedo and A. Ferrandez, Importance of pronominal anaphora resolution in question

- answering systems, Proceedings of the 38th Annual Meeting of the Association for Computational Linguistics, pp. 555-562, 2000.
- [4] N Kobayashi, R. Iida, K. Inui, and Y. Matsumoto, Opinion extraction using a learning-based anaphora resolution technique, Proceedings of the 2nd International Joint Conference on Natural Language Processing, pp. 173-178.
- [5] B. Grosz, A. Joshi and S. Weinstein, Centering: A framework for modeling the local coherence of discourse, Computational Linguistics, vol. 21, no. 2, pp. 203-225. 1995.
- [6] J. Carbonell and R. Brown, Anaphora resolution: a multi-strategy approach, Proceedings of COLING, pp. 96-101, 1988.
- [7] S. Lappin and H. Leass, An algorithm for pronominal anaphora resolution, Computational Linguistics, vol. 20, no. 4, pp. 1994, 535-561.
- [8] W. Soon, H. Ng, and D. Lim, A machine learning approach to coreference resolution of noun phrases. Computational Linguistics, vol. 27, no. 4, pp. 521 - 544, 2003.
- [9] X. Yang, J. Su, and C. L. Tan, A twin-candidate model for learning-based anaphora resolution, Computational Linguistics, vol. 34, no. 3, pp. 327-356, 2008.
- [9] J. R. Finkel, and C. D. Manning, Manning enforcing transitivity in coreference resolution, Proceedings of the ACL 2008, pp. 45-48, 2008.
- [10] J. Lafferty, A. McCallum and F. Pereira, Conditional random fields, probabilistic models for segmenting and labeling sequence data, Proceedings of International Conference on Machine Learning, pp. 282-289, 2001.
- [11] S. Ponzetto and M. Strube, Exploiting semantic role labeling, WordNet and Wikipedia for coreference resolution. Proceedings of the HLT 2006, pages 192-199, 2006.
- [12] Y. Kilicaslan, E. S. Guner and S. Yildirim, Learning-based pronoun resolution for Turkish with a comparative evaluation, Computer Speech Language, vol. 23, no. 3. pp. 311-331, 2009.
- [13] P. Denis and J. Baldridge, A ranking approach to pronoun resolution, Proceedings of IJCAI-07, pp. 1588-1593, 2009.
- [14] N. Nguyen, J.-D. Kim and J. Tsujii, Challenges in pronoun resolution system for biomedical text, Proceedings of LREC'08, pp. 2408-2412, 2008.