

## 세종 말뭉치로부터 용언언어 추출

이정태<sup>o</sup>, 천민아, 김재훈  
한국해양대학교

make8286@naver.com, minah014@outlook.com, jhoon@kmou.ac.kr

### Verbal Collocation Extraction from Sejong Tagged Corpus

Jeong-Tae Lee<sup>o</sup>, Min-Ah Cheon, Jae-Hoon Kim  
Korea Maritime and Ocean University

#### 요 약

언어는 둘 이상의 단어로 구성된 표현으로 언어에 속하는 개개의 단어의 의미로써 언어의 의미를 유추할 수 없다. 따라서 언어의 의미를 분석하거나 번역할 경우 개개의 단어보다는 언어 그 자체를 하나의 분석단위로 간주하는 것이 훨씬 더 효과적이다. 이를 위해 본 논문에서는 통계기법을 활용하여 세종 말뭉치로부터 용언언어의 추출 방법을 제시하고 그 성능을 평가한다. 언어 패턴과 통계 정보를 이용해서 언어를 추출한다. 평가를 위해서 언어 사전과 전문가의 주관적 평가를 동시에 수행했다.

주제어: 용언언어(verbal collocation), 언어추출, 언어사전, 주관적 평가

#### 1. 서론

언어는 둘 이상의 단어로 구성된 표현으로 언어에 속하는 개개의 단어의 의미로써 언어의 의미를 유추할 수 없다[1]. 따라서 언어의 의미를 분석하거나 번역할 경우 개개의 단어보다는 언어 그 자체를 하나의 분석단위로 간주하는 것이 훨씬 더 효과적이다. 예를 들어, “모자를 쓰다”에서 “모자”는 “hat / cap / mother and son”으로 번역될 수 있고 “쓰다”는 “write / compose / use / bitter / wear”로 번역될 수 있다. 하지만 “모자를 쓰다”를 “wear a hat”으로 번역할 수 있도록 언어사전이 구축되면 의미의 중의성뿐 아니라 시스템의 성능 개선에 크게 도움이 될 것이다. 또 다른 예로는 “실패로 돌아가다”에서 “실패”는 “failure”이고 “돌아가다”는 “return / go back to / get back to”이며 “실패로 돌아가다”는 “turn out a failure”이므로 정확한 번역을 찾을 수 없다. 이런 문제를 완화시키기 위해서 언어의 대역사전이 있다면 커다란 도움이 될 것이다. 특히 동사는 문장에서 가장 핵심적인 구성요소이기 때문에 대역어의 선택이 매우 중요하다. 본 논문은 세종 말뭉치로부터 동사 언어(verbal collocation)를 추출하는 방법을 제안한다. 언어 후보를 추출하기 위하여 빈도, 품사정보, 용언 위치에 따른 결합 등 다양한 정보를 이용한다. 이러한 정보를 바탕으로 본 논문에서는 더 제한적인 결합 조건과 진보된 확률 정보를 통하여 언어를 추출한다. 용언을 기준으로 추출한 언어 후보들은 매우 높은 확률로 언어라고 판단할 수 있어 앞으로 언어 사전 구축 연구에 도움이 될 것이라 생각된다.

논문의 구성을 다음과 같다. 2장에서 용언언어 추출 방법을 기술하고 3장에서 실험 및 평가를 기술하고 끝으로 4장에서 결론 및 향후 연구에 대해 기술한다.

#### 2. 용언언어 추출 방법

본 논문에서 제안하는 방법은 용언언어 추출 방법을

단순화하기 위하여 여러 개의 단계로 나뉘어 진행되며 각 단계는 이하의 절에서 자세히 설명할 것이다.

##### 2.1 전처리 단계

전처리 단계는 세종 말뭉치의 품사 부착을 부분적으로 수정한다. 예를 들면 세종 말뭉치의 품사 부착이 “공부/xr + 하/xsv”라며 “공부하/vw”로 수정하여 의미적으로 완전한 동사를 쉽게 찾을 수 있도록 변환한다. 아래는 전처리 단계에서 변환되는 규칙들이다.

1. 접두사(xpn) + 명사 파생 접미(xsn) -> 일반 명사
2. 접두사(xpn) + 어근(xr) -> 일반 명사
3. 어근(xr) + 명사 파생 접미 -> 일반 명사
4. 어근 + 동사 파생 접미(xsv) -> 동사
5. 어근 + 형용사 파생 접미(xsa) -> 형용사
6. 일반 명사(nng) + 명사 파생 접미 -> 일반 명사
7. 일반 명사 + 동사 파생 접미 -> 일반 동사
8. 일반 명사 + 형용사 파생 접미 -> 형용사
9. 부사(mag) + 동사 파생 접미 -> 일반 동사
10. 부사 + 형용사 파생 접미 -> 형용사

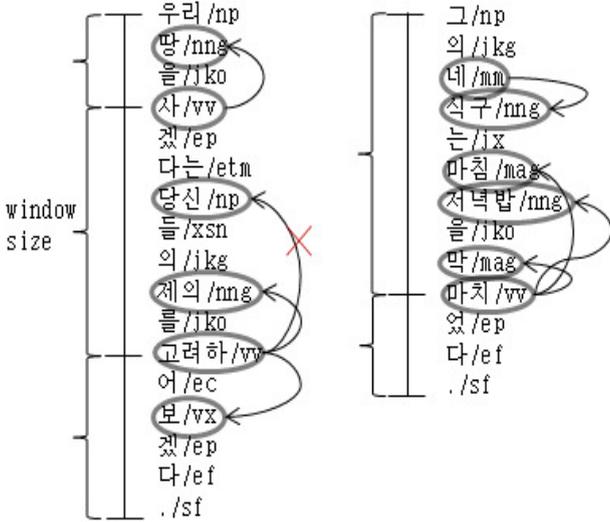
부가적으로 이러한 변환은 같은 의미를 지님에도 불구하고 다르게 해석되어 통계 정보가 손상되는 것을 막기 위함이다. 예를 들어, “불/xpn+가능/xr”같은 경우 “도전하다”와 같은 동사와 잘 어울린다. 하지만 따로 “불/xpn+가능/xr”을 그대로 두면 “가능” + “도전하다”와 같은 언어 후보가 수집될 수 있다. 이러한 경우를 막기 위해 전처리 단계를 수행한다.

##### 2.2 용언언어 후보 추출

품사정보를 활용하여 언어를 추출하는 방법은 매우 다양하며 품사 간의 특정한 결합구조를 보인다[5,6]. 본 논문에서 사용된 용언언어 언어 유형은 다음과 같다.

1. 부사(mag) + 용언(va/vv) : 발각/mag + 뒤집히/vv
2. 관형사(mm) + 체언(n+) : 오랜/mm + 세월/nng
3. 체언(n+) + 용언(va/vv) : 다정/nng + 다감하/va
4. 체언(n+) + 체언(n+) : 시장/nng + 경제/nng
5. 용언(va/vv) +보조용언(vx) : 도리/vv + 내/vx

위 다섯 가지 유형의 용언언어 후보의 통계 정보를 통해 언어 후보를 추출할 것이다.



[그림 1] 용언언어 후보 추출을 위한 탐색범위

[그림 1]은 유형 1~5가 어떻게 결합되어 추출되는지를 보여준다. 후보 추출 범위(window)는 주용언(vv/va)에 의해 결정되며 유형 1, 3, 5번의 경우에 그 범위에 있는 주용언으로부터 가장 가까운 단어 하나만 선택한다. [그림 1]의 왼쪽 그림을 보면 탐색범위 내에 용언과 결합 가능한 체언이 "당신/np"과 "제외/nng" 두 종류가 있지만 "제외/nng"와만 결합하도록 하였다. 이는 문장의 목적어 술어 관계는 하나 이상 나타나지 않는 문법적 특성을 이용한 것이다. 5번 또한 "내버려두다"와 같이 "내버리다" + "두다"와 같은 표현은 한 품사가 여러 품사에 걸쳐 공기관계를 갖지 않는다. 그에 반해서 부사와 주용언의 결합은 오른쪽 그림과 같이 여러 개와 결합하여도 그 의존성이 크게 변하지 않는다. 이러한 언어의 특징을 고려해 부사 용언 결합은 탐색범위 내에서는 여러 차례 나타날 수 있다고 생각하고 언어후보 추출을 시행한다. 2, 4번 경우에는 거리가 1이내인 결합만을 허용한다. 여기서 거리는 두 단어 사이에 존재하는 형태소의 개수를 말한다. 즉, 바로 연결되는 두 단어만을 추출하였다.

### 2.3 통계 정보 측정 방법

2.1과 2.2를 거쳐 뽑은 언어후보를 이용하여 언어 후보들의 순서를 정한다. 말뭉치의 통계 분석에서 다루는 자료는 대부분 질적인 자료(qualitative data)이며, 이러한 데이터는 주로 분할표(contingency table)를 활용하여 분석된다. 여기서 살펴볼 자료의 변수는 왼쪽 단어와 오

른쪽 단어 두 개의 변수를 가지고 있는 2차원 분할표를 통해 분석한다. 본 논문에서는  $\chi^2$ 검정(chi-square, 식 (1))을 통한 분석과 PMI(Pointwise Mutual Information, 식 (2))를 통한 분석을 이용할 것이다.

$$\chi^2 = \sum_{j=1}^M \sum_{i=1}^N \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \quad (1)$$

$$PMI(x, y) = \log \frac{p(x, y)}{p(x)p(y)} \quad (2)$$

식 (1)은 일반적으로 편포(skewed distribution)를 이용한 검정 방법으로 말뭉치 자료가 정규 분포를 따르지 않는다고 생각할 때 분석에 유리한 장점이 있으며 실험에서도 더 좋은 성능을 보인다[2]. 식 (2)는 두 단어가 어떤 개연성을 가지고 출현할 확률과 두 단어가 아무런 관계도 없이 우연히 함께 출현할 확률의 비를 보여 이 비율이 높으면 언어일 가능성이 높다는 것이다.

[표 1] 언어추출을 위한 2차원 분할표

	w1=우리	w1!=우리
w2=나라	$o_{11}=675$ freq(w1,w2)	$o_{12}=1816-675$ freq(w2) -freq(w1,w2)
w2!=나라	$o_{21}=8858-675$ freq(w1) -freq(w1,w2)	$o_{22}=N-$ $(o_{11}+o_{12}+o_{21})$

[표 1]은 세종 말뭉치의 일부를 가지고 '우리/np', '나라/nng'를 2x2 분할표로 나타낸 것이다. 이를 통해 식 (1)과 (2)를 나타내면 아래와 같다.

$$\chi^2 = \frac{N(O_{11}O_{22} - O_{12}O_{21})^2}{(O_{11} + O_{12})(O_{11} + O_{21})(O_{12} + O_{22})(O_{21} + O_{22})} \quad (3)$$

2x2 분할표에서는 자유도가 1이며 이런 경우는 이산 통계량에 가깝기 때문에 Yates 보정을 수행한다. 이 방법을 사용하면  $\chi^2$ 분포에 가까운 통계량을 얻을 수 있다 [7]. 이 방법을 통해 수식을 수정하면 (4)와 같다. [표 1]을 활용하여 PMI를 계산하는 수식은 (5)와 같다.

$$Yates = \frac{N(|O_{11}O_{22} - O_{12}O_{21}| - N/2)^2}{(O_{11} + O_{12})(O_{11} + O_{21})(O_{12} + O_{22})(O_{21} + O_{22})} \quad (4)$$

$$PMI(x, y) = \log \left( \frac{O_{11}N}{(O_{11} + O_{12})(O_{11} + O_{22})} \right) \quad (5)$$

통계 정보를 추출할 때에 일반적으로  $o_{11}$ 의 빈도가 5이 하이면 실험에서 제외시킬 것을 권장하고 있다. 언어의 특성상 습관적으로 같이 자주 나타나야 하는데 그렇지 않고 서로의 의존관계가 높아 상위에 랭크되는 단어들을

제외하기 위함이다. 본 실험에서는 권장되는 빈도 이하의 언어후보에 대해서는 전혀 고려하지 않고 실험을 진행한다. 충분히 크지 않은 말뭉치는 도메인에 따라 특정 단어들을 뽑아내곤 하는데 효과적인 방법의 도입을 통해 특정 단어를 추출하는데 도움을 줄 수 있다[8]. 그 수식은 (6)과 같다. 이 방법은  $\chi^2$ 검증에 적용 가능하며 이를 적용하면 세종 말뭉치에서 좀 더 좋은 결과를 기대할 수 있다.

$$Yates = \text{sign}(O_{11}O_{22} - O_{12}O_{21}) * Yates_0$$

$$\text{sign}(z) = \begin{cases} +1 & \text{if } z > 0 \\ -1 & \text{otherwise} \end{cases} \quad (6)$$

### 3. 실험 및 결과

실험은 세종 말뭉치의 45만여 개의 태그된 문장을 대상으로 수행하였다. 평가는 사람이 수동으로 언어임을 판단하는 방법과 기존에 존재하는 한국어 언어 목록[9]을 이용하여 평가를 실시하였다. 한국어 언어 목록은 어절 단위로 사전이 구축되어 있기 때문에 어절을 분석하여 조사나 어미를 제외한 후 언어 후보와 일치하면 정답으로 표기하였다. 제안한 언어 추출 방법으로부터 평가한 결과는 [표 2]와 같다.

표 2

[표 2] 용언언어 추출에 대한 성능 평가

언어 유형	Chi-Square		PMI	
	사전	수동	사전	수동
부사+용언	33%	97%	14%	97%
관형사+체언	22%	70%	13%	69%
체언+용언	20%	82%	3%	70%
체언+체언	1%	10%	0%	12%
용언+보조용언	33%	97%	16%	95%

[표 2]는 각각의 유형에 따라 PMI와 Chi2값의 상위 100개의 후보들에 대해 정확도를 나타낸 결과표이다. 각 언어 유형별로 적게는 수천, 많게는 수만 개의 후보들이 추출되기 때문에 상위의 후보들만 가지고 수동으로 평가하였으며 Chi-Square와 PMI, 두 가지 평가 방법에서 특정 수치 이내에서는 상당히 신뢰도가 있는 추출률을 보여준다. 두 평가 방법을 비교해 보았을 때엔 Chi-Square 방식이 PMI보다 더 뛰어난 결과를 보여준다. 사전으로 엄격하게 평가하였을 때나 사람이 수동으로 채점하였을 때나 두 가지 모든 경우에서 평균적으로 더 좋은 결과를 보였다. “부사+용언”과 “용언+보조용언”은 사전으로 평가하던 수동으로 하던 좋은 결과를 보이고 있어 상당히 유용할 것으로 생각된다. “체언+체언”의 결과는 상위 100개에 랭크된 단어들이 대부분 고유 명사이기 때문에 사전에 없는 것과 더불어 언어라고 판단하기 힘들어 좋은 결과가 나오지 않았다. 하지만 상위 랭크된 고유명사들을 제외하면 많은 합성어들이 랭크되

는 것을 볼 수 있다.

### 4. 결론

본 논문에서는 통계적 기법을 통하여 자동으로 언어를 추출하는 방법에 대해서 실험하였다. 현재 언어는 명확한 정의가 없기 때문에 사람이 평가하여 Kappa 계수를 이용하거나 평균 등의 값으로 평가하는 경우가 많았다. 본 실험에서는 객관성을 위하여 사전으로 평가한 후 수동으로 평가하여 그 차이가 어느 정도인지를 보였다. 본 실험의 결과로는 현존하는 언어사전의 어휘가 부족한 것으로 보이며 이 후 완성도 있는 사전이 만들어져야 객관성 있는 평가가 가능 할 것으로 보인다. 해당 실험에서 수동으로 평가한 결과가 좋기 때문에 앞으로 언어 사전을 만들 때 큰 도움이 될 것이라고 생각한다. 차후 언어의 길이를 늘려 찾고자 한다면 n개의 품사 조합이나 언어의 이행적(transitive) 관계를 이용하여 확장할 수 있을 것이다.

### 감사의 글

본 연구는 미래창조과학부 및 정보통신기술진흥센터의 정보통신·방송 연구개발사업의 일환으로 수행하였음. [10041807, 지식학습 기반의 다국어 확장이 용이한 관광/국제행사 통역률 90%급 자동 통번역 소프트웨어 원천 기술 개발]

### 참고문헌

- [1] H. E. Palmer, "영어학사전", 1990.
- [2] 주은석, "대규모 언어추출을 위한 통계적 기법 비교", 언어사실과 관점, 제25권, pp. 189-210, 2010.
- [3] 이공주, 김재훈, 김길창, "품사 태깅된 말뭉치로부터 한국어 언어 추출", 한국 정보과학회 추계 학술발표 논문집, pp.623-636, 1995
- [4] F. Samadja, "Retrieving collocations from text: Xtract", In Computational Linguistics, 19(1), pp.143-177, 1993.
- [5] 서상규, 홍종선, "한국어 정보 처리와 언어 정보", 국어학회, 제 39집, pp. 321-360, 2006.
- [6] 임근석, "통계적 방법을 이용한 문법적 언어 후보 추출", 한국어학회, 제45권, pp. 305-333, 2009
- [7] F. Yates, "Contingency Tables Involving Small Numbers and the  $\chi^2$  Test", Journal of the Royal Statistical Society, Vol. 1, No. 2, pp. 217-235, 1934
- [8] Kiyomi chujo, Masao Utiyama, Takahiro Nakamura, Kathryn Oghigian. "Evaluating Statistically-extracted Domain-Specific Word Lists", Nihon University, 2010
- [9] 김하수 외 8명, "한국어 교육을 위한 한국어 언어목록", 2007