

한-일 기계번역 시스템에서 관형격조사 ‘の’의 복원

정유진*, 허남원*, 이종혁*, 김태석*

포항공과대학교 컴퓨터공학과*, 동의대학교 컴퓨터공학과*

Restoration of Adnominal Case ‘no’ in Korean-to-Japanese MT System

Yujin Chung*, Namwon Heo*, Jong-Hyeok Lee*, Tai-Suk Kim*

Dept. of Computer Science & Engineering, POSTECH*

Dept. of Computer Science & Engineering, Dong-Eui Univ.*

요약

기존의 한-일 기계번역 시스템에서는 합성명사의 번역시 별도의 처리과정을 두지 않고 단순히 단어 각각을 일본어로 직역하여 변환시키는 방법을 채택하고 있다. 이러한 합성명사의 번역 방법은 대부분의 경우 잘 적용되지만, 매우 부자연스러운 일본어 표현이 되는 경우도 많다. 본 논문에서는 이러한 번역 방법이 갖는 문제점을 지적하고 합성명사를 관형격조사가 삽입된 명사구로 변환시키기 위해 표층 레벨에서의 어휘간 결합력과 명사 간의 의미 관계를 이용한 관형격조사 ‘の’의 복원 방법을 제안함으로써 보다 자연스러운 일본어 문장을 생성할 수 있도록 하고자 한다.

1. 서론

한국어에서 일본어로 기계번역을 수행할 때 합성명사 (compound noun)들은 일반적으로 별도의 처리과정 없이 단순하게 합성명사를 구성하는 단어 각각을 일본어로 직역하여 변환시킨다. 이러한 합성명사의 번역 방법은 같은 한자 문화권에 속한 국가로서 동일한 한자어 명사의 사용과 함께 양국어간에 언어 구조가 상당히 유사하다는 점 등에 기인하여 대부분의 경우 큰 문제점 없이 잘 적용되고 있지만, 일부 합성명사의 경우에 있어서는 이러한 변환으로 인해 다음 예문과 같이 부자연스러운 일본어 표현이 되기도 한다.

(예1) 어머니 : お母さん

지갑 : 財布

어머니 지갑 ➔ お母さん財布 (X)

お母さんの財布 (O)

(예2) 일본어 : 日本語

선생님 : 先生

일본어 선생님 ➔ 日本語先生 (△)

日本語の先生 (O)

한국어에서는 “어머니 지갑”이란 합성명사의 경우, ‘어머니의 지갑’과 같은 명사구 형태 뿐만 아니라 흔히 관형격(소유격) 조사 ‘의’를 생략하여 ‘어머니 지갑’과 같은 합성명사 형태로도 많이 사용되고 있다. 그러나 ‘어머니 지갑’을 일본어로 번역할 때 관형격조사 ‘의’가 생략되었음을 고려하지 않고 단지 명사만을 치환할 뿐이라면 (예 1)에서와 같이 ‘お母さんの財布’라는 이상한 일본어 표현이 된다. (예 2)의 ‘일본어 선생님’의 대역어인 ‘日本語先生’의 경우에는 일본어 화자들에게 어느 정도 용인될 수 있는 표현이긴 하나 이 역시 부자연스럽기는 마찬가지이다.

이러한 부자연스러움을 해소하기 위해서는 합성명사 사이에 관형격조사에 해당하는 ‘의’를 삽입하여 ‘お母さんの財布’나 ‘日本語の先生’와 같이 명사구 형태로 바꾸어 주어야 하며 이는 곧 원래의 명사 ‘어머니 지갑’에서 생략되어 있는 관형격조사 ‘의’를 복원한 후 번역하는 것과 같은 맥락으로 파악할 수 있다.

또한 다음의 예문을 살펴보자.

(예3) 일본어 형태소 분석 결과 제시

➔ 日本語形態素分析結果提示 (△)

日本語形態素の分析結果の提示 (O)

(예 3)과 같이 다수의 명사들이 나열된 경우 일본어에서는 띄어쓰기를 하지 않기 때문에 ‘일본어 형태소 분석 결과 제시’를 단순히 단어들만 치환시키게 되면 ‘日本語形態素分析結果提示’와 같은 보기에도 답답한 표현이 되어버린다. 이러한 경우 역시 명사의 중간에서 끊어 읽을 수 있도록 적절한 위치에 ‘の’를 삽입시켜 주는 것이 보다 자연스럽다.

따라서 본 논문에서는 위와 같은 문제가 발생할 수 있는 합성명사들에 대해 관형격조사를 삽입하여 명사구화시키는 방법을 제시함으로써 보다 자연스러운 일본어 문장을 생성할 수 있음을 보였다.

본 논문의 구성은 다음과 같다. 제 2 장에서는 ‘の’ 삽입문제가 갖고 있는 애로점과 기준의 방법들에 대하여 소개한다. 제 3 장에서는 표층 레벨에서의 어휘간 결합력과 의미 레벨에서의 명사간 의미 관계를 이용한 ‘の’의 복원 방법에 대해 기술하고 제 4 장에서는 말뭉치 학습결과를 제시한다. 그리고 제 5 장에서는 실험과 평가를, 제 6 장에서는 결론과 앞으로의 연구 방향에 대하여 기술한다.

2. 기준의 방법

다음과 같은 일본어 합성명사 및 명사구를 살펴보자.

(예4) ① 交通の現状 ② 交通(の)規制 ③ 交通戦争

(예5) ① 経済の基本 ② 経済(の)状態 ③ 経済大國

(예 4)는 모두 ‘交通’이란 명사가 포함되어 있다는 점에서, 그리고 (예 5)는 ‘經濟’란 명사가 포함되어 있다는 점에서 동일하나 뒤에 어떤 명사가 따라오느냐에 따라 ‘の’의 삽입 여부가 달라진다. ①의 경우에는 반드시 ‘の’가 있어야 하고, ②의 경우에는 ‘の’의 생략이 가능하며, ③의 경우에는 ‘の’를 쓰면 안된다는 차이점이 존재한다. 그런데 이처럼 일본어에서 명사 사이에 관형격조사 ‘の’를 삽입하고 삽입하지 않고의 여부는 오직 관용적으로 결정되는 것으로써 확실하게 명시된 규칙이 존재하지 않는다[1].

따라서 ‘の’의 복원문제에 대한 연구는 지금까지 보고된 바가 없으며 한-일 기계번역 시스템들은 임의의 몇 가지 휴리스틱을 만들어서 ‘の’ 복원문제를 처리하고 있는 실정이다. 일례로 한-일 기계번역 시스템 COBALT-K/J¹에서는 다음 2 가지의 방법을 사용하고 있

다.

1) 기계번역 시스템 사전에 ‘の’와의 결합 정보를 입력

일본어에서는 합성명사를 구성할 때 관용적으로 ‘の’와 결합되어 출현하는 명사들이 존재한다. ‘前’, ‘上’, ‘代わり’, ‘せい’와 같은 명사들이 이에 해당하는데 COBALT-K/J에서는 이러한 명사들의 사전 정보에 ‘の’와의 결합 여부를 기록해두고 있다. 따라서 합성명사가 출현했을 때 COBALT-K/J는 합성명사를 구성하는 각 명사의 사전정보를 읽어들여 만약 ‘の’ 삽입 명사에 해당하면 합성명사 사이에 ‘の’를 삽입해 주는 방법을 사용하고 있다.

(예6) 학교 앞 ➔ 學校前 ➔ 學校の前

그러나 현재 기계번역 시스템 사전이 갖고 있는 ‘の’ 삽입 명사가 40여개에 불과하기 때문에 이러한 명사들이 출현하는 극히 일부의 합성명사에 대해서만 처리가 가능하다는 한계성이 있다.

2) ‘する 명사’의 앞에 ‘の’를 삽입

COBALT-K/J가 사용하는 또 다른 휴리스틱으로 합성명사를 구성하고 있는 뒤쪽 명사가 ‘する 명사(サ변동사 어간)’이면 그 앞에 ‘の’를 삽입해 주는 방법이 있다. 다음의 예를 보자.

(예7) 경찰 조사에 따른 ➔ 警察調査 ➔ 警察の調査

위의 (예 7)에서 합성명사 ‘警察調査’는 뒤쪽 명사인 ‘調査’가 ‘する 명사’이므로 COBALT-K/J는 명사 사이에 ‘の’를 삽입하여 ‘警察の調査’의 형태로 만들어 주게 된다. 이 휴리스틱은 어느 정도 효용성을 갖고 있기는 하지만 절대성을 갖는 규칙이 아니기 때문에 아래의 (예 8)에서와 같이 ‘の’를 삽입함으로써 오히려 틀린 표현이 되어버리는 경우도 상당수 존재한다는 문제점이 있다.

(예8) 전기 통신 ➔ 電氣通信 ➔ 電氣の通信 (X)

따라서 1)항이나 2)항과 같은 휴리스틱 처리방법만으로는 ‘の’ 복원문제를 해결할 수 없다.

3. 어휘간 결합력과 의미 관계를 이용한 ‘の’의 복원

¹ 포항공대 지식 및 언어공학 연구실(KLE Lab.) 개발

² ‘하다’가 볼 수 있는 명사.(예 : 調査, 通信, 建設 등)

3.1 어휘간 결합력을 이용한 ‘の’의 복원

일본어에서 합성명사를 구성할 때 ‘の’와 결합되어 출현하는 빈도가 특별히 높은 명사들이 존재한다는 점에 착안하여, 말뭉치로부터 학습한 각 명사들의 ‘の’와의 결합력을 이용하여 ‘의’의 복원 여부를 결정한다. 어휘간 결합력의 학습은 일본어 말뭉치 상에서 학습 대상이 되는 명사가 출현한 합성명사 또는 ‘의’가 삽입된 형태의 모든 명사구 사례들을 수집한 후 그 명사와 ‘의’의 결합력을 계산함으로써 이루어지며 결합력은 전방향 결합력과 후방향 결합력으로 구분시켜 학습한다. 전방향 결합력은 현재의 명사가 합성명사에서 뒤쪽 명사로 출현했을 때 그 앞에 ‘의’가 삽입될 확률을 나타내고, 후방향 결합력은 앞쪽 명사로 출현했을 때 그 뒤에 ‘의’가 삽입될 확률을 나타낸다. ‘의’의 결합력은 대상이 되는 명사가 말뭉치에서 ‘의’와 함께 출현한 횟수(명사구)를 출현했던 총횟수(합성명사+명사구)로 나눈 값으로 정의한다.

$$\text{‘의’ 결합력} = f_{phrase} / (f_{cnoun} + f_{phrase})$$

$$[\begin{array}{l} f_{cnoun}: \text{합성명사 출현 빈도수} \\ f_{phrase}: \text{명사구 출현 빈도수} \end{array}]$$

3.2 의미 관계를 이용한 ‘의’의 복원

<표-1>은 ‘의’가 갖고 있는 의미기능들을 분류한 것이며 한일 양 언어의 비교를 위해 ‘의’의 의미기능의 분류도 함께 제시하고 있다[2][3]. ‘의’가 한국어에서 격조사로만 사용되는 것에 비해 ‘의’는 격조사의 용법 외에도 병립조사, 준체조사, 종조사 등 그 쓰임새가 다양하여 ‘의’보다 의미분포가 넓다.

그러나 현재 이 논문에서 다루는 ‘의’ 복원 문제는 오직 합성명사만을 대상으로 하고 있기 때문에 관심의 대상이 되는 ‘의’의 의미기능은 단지 앞뒤에 명사가 나타나는 경우인 격조사의 용법뿐이며 병립조사 용법이나 준체조사 용법, 종조사 용법은 고려의 대상이 아니다. 그런데 격조사 용법을 살펴보면 아래의 세 가지 경우를 제외한 나머지 경우들은 ‘의’ 앞뒤에 위치한 명사들 사이에 所作(~가 만든)이라든지 所在(~에 있는)처럼 어떤 특별한 의미 관계가 존재함을 알 수 있다.

- ① 形式名詞에 접속될 때의 ‘의’ (~のころ, ~のため)
- ② 連體型으로 끝나는 절의 목적어를 나타내는 경우의 ‘의’ (目のめざめるような詩)

<표-1> ‘의’와 ‘의’의 의미기능 비교

	의
격 조 사	주체와 객체의 관계 (所作, 所成, 所有, 關係)
	전체와 부분의 관계 (所在, 所產, 所起, 所屬, 選擇)
	命命名의 의미 (比喻, 對象, 名稱, 代意, 同格)
	기타 용법 (範圍, 順序, 數量, 目的, 種類, 材料, 時間, 時期, 性質, 形式名詞에 접속, 連體型 절의 목적어, ようだ / ごとし 앞)
병립조사(並立助詞) ³	
준체조사(準體助詞) ⁴	
종조사(終助詞) ⁵	

② ようだ / ごとし 앞의 ‘의’

위의 ②, ③은 ‘의’가 명사와 명사 사이에 있을 때에는 나타나지 않는 용법이며, ①의 형식명사는 실질적인 의미를 갖지 않고 독립해서 사용되는 경우가 없는 특수한 명사이다. 따라서 일본어에서 일반명사 사이에 ‘의’가 출현했다면 위의 세 경우가 아닌 의미관계를 갖고 있는 나머지 의미기능들 중의 하나에 해당한다고 할 수 있다. 즉, 명사사이에 ‘의’가 존재하는 것은 두 명사가 어떤 의미적인 관계를 갖고 있음을 의미하므로 일본어 말뭉치로부터 ‘의’가 삽입된 명사구들의 의미관계들을 학습하면 일본어에서 합성명사가 출현했을 때, 앞뒤 두 명사의 의미 관계를 살펴봄으로써 ‘의’의 복원 여부를 결정할 수 있다.

³ 병립조사 : 대등 관계에 있는 단어를 병립시킴 (本の, 紙のと)

⁴ 준체조사 : 앞의 단어와 하나로 되어 전체를 체언의 자격을 갖게 함 (これは私のです.)

⁵ 종조사 : 용언 및 조동사의 連體型, 終止型에 붙어서 文末에 사용됨 (もういいの.)

의미 관계에서 ‘の’와의 결합력은 3.1 절에서 정의한 것과 마찬가지로 대상이 되는 두 의미 코드가 말뭉치에서 ‘の’와 함께 출현한 횟수(명사구)를 출현했던 총 횟수(합성명사+명사구)로 나눈 값으로 정의한다.

4. 말뭉치를 이용한 ‘の’ 결합력 학습

학습에 사용된 일본어 말뭉치는 아사히 신문과 EDR 사전의 총 33만 8천여 문장이며 이들로부터 합성명사(명사-명사) 및 명사구(명사-の-명사) 79만 6천여개를 수집하여 명사의 ‘の’ 전/후 결합력 및 의미 관계의 ‘の’ 결합력을 학습하였다. 그 결과 총 33,923 개 명사의 ‘の’에 대한 결합력이 학습되었고 <표-2>, <표-3>에 학습결과가 제시되어 있다.

<표-2>와 <표-3>에서 두번째 열은 학습으로 얻어진 모든 명사들의 ‘の’ 결합력 분포를 나타내며 세번째 열

은 신뢰성을 갖도록 하기 위해 말뭉치에서 적어도 15회 이상 출현했던 명사들만을 대상으로 그 분포를 표기한 것이다. 출현빈도 15회 이상의 명사들 중 전방향 ‘の’ 결합력에서는 전체의 20.5%에 해당하는 1347 개의 명사가, 후방향 ‘の’ 결합력에서는 전체의 13.4%에 해당하는 929 개의 명사가 0.7 이상의 높은 결합력을 보였다.

또한 의미관계의 학습을 위해서는 시소러스 *類語新辭典* [4]의 1000 레벨 의미분류체계를 이용하였다. *類語新辭典*의 1000 레벨 의미분류체계는 총 1000 개의 의미 코드로 분류되어 있으므로 발생할 수 있는 모든 의미코드의 조합은 1 백만 가지이며 그 의미조합의 학습결과가 <표-4>에 제시되어 있다. <표-4>의 총 조합수의 합이 백만이 되지 않는 이유는 말뭉치에 출현하지 않은 의미조합들이 있기 때문이다.

<표-4>에서 세번째 열은 말뭉치에서 적어도 15회 이상 출현했던 의미조합들을 대상으로 그 분포를 표기하고 있다. 이 중 전체의 13.2%에 해당하는 1193 개의 의미조합이 0.7 이상의 높은 결합력을 나타냄으로써 ‘の’와의 결합력이 특별히 높은 의미조합이 실제로 존재함을 보여주고 있다.

<표-4> 의미조합의 ‘の’ 결합력 학습결과

결합력	총 명사수	N>15 명사수
1.0 ~ 0.9	12900 개	492 개
0.9 ~ 0.8	1108 개	446 개
0.8 ~ 0.7	1094 개	409 개
0.7 ~ 0.6	1662 개	504 개
0.6 ~ 0.5	2399 개	646 개
0.5 ~ 0.4	1087 개	646 개
0.4 ~ 0.3	1638 개	769 개
0.3 ~ 0.2	1623 개	844 개
0.2 ~ 0.1	1233 개	797 개
0.1 ~ 0.0	9179 개	1032 개
Total	33,923 개	6,585 개

<표-3> 명사의 후방향 ‘の’ 결합력 학습결과

결합력	총 명사수	N>15 명사수
1.0 ~ 0.9	12118 개	323 개
0.9 ~ 0.8	763 개	267 개
0.8 ~ 0.7	872 개	339 개
0.7 ~ 0.6	1418 개	473 개
0.6 ~ 0.5	2354 개	576 개
0.5 ~ 0.4	1221 개	720 개
0.4 ~ 0.3	1791 개	854 개
0.3 ~ 0.2	1988 개	1009 개
0.2 ~ 0.1	1705 개	1059 개
0.1 ~ 0.0	9693 개	1339 개
Total	33,923 개	6,959 개

5. 실험 및 평가

5.1 실험 페러메터의 설정

표충 레벨에서의 어휘간 결합력에 의한 ‘の’ 복원 실험은 두 명사가 연이어 나타나는 합성명사가 출현했을 때 앞쪽 명사의 후방향 ‘の’ 결합력을 S_{back} , 뒤쪽 명사의 전방향 ‘の’ 결합력을 S_{front} 라고 하면

대량의 일본어 말뭉치에 의한 학습을 추가할 예정이며 의미 레벨 단계에서의 적용률 향상을 위해 1000 레벨보다 대부분류의 상위 의미코드를 갖는 100 레벨 의미 분류 체계를 이용한 학습 및 실험을 시도하고자 한다.

참고문헌

- [1] 姫野昌子, “日本語教育における η の§ の指導,” 日本語學, 1993 年 11 月
- [2] 하순식, “意味를 중심으로 한 η 의§ 와 η -의§ 的對應關係에 관한 考察,” 경남대학교 석사학위논문, 1989
- [3] 최택호, “日本語의 助詞 η 의§ 와 韓國語의 助詞 η -의§ 에 關한 考察,” 계명대학교 석사학위논문, 1987
- [4] 大野晋, “類語新辭典,” 角川書店, 1981
- [5] 이운태, “관형격조사 η -의§ 的 의미와 기능,” 충남대학교 석사학위논문, 1987
- [6] 김광해, “ η -의§ 的 의미,” 서울대학교 석사학위논문, 1981
- [7] 田中省作, “名詞句 η -NP の NP§ の意味關係とその統計的性質,” 第 4 次 日本 言語處理學會 論文紙, 1998.3
- [8] 정유진, “한-일 기계번역 시스템에서 관형격조사의 복원,” 정보과학회 춘계 학술발표논문집, 26 권, 1 호, 1999