

# 패턴생성을 통한 인터넷 문서의 한글-영문용어 추출<sup>1</sup>

강재호\*, 김종성\*\*, 류광렬\*\*

\*동아대학교 지능형통합항만관리연구센터, \*\*부산대학교 정보컴퓨터공학부  
{jhkang, kimjs1, kr Ryu}@pusan.ac.kr

## Mining Korean-English Terminologies by Pattern Generation in Internet

Jaeho Kang\*, Jongsung Kim\*\* and Kwang Ryel Ryu\*\*

\*Center for Intelligent & Integrated Port Management Systems, Dong-A University

\*\*Division of Computer Science and Engineering, Pusan National University

### 요 약

전문용어의 가짓수가 많고 생성빈도 또한 높은 분야에서 고품질의 정보검색과 기계번역 결과를 얻기 위해서는 상당 분량의 번역용어사전의 확보가 필수적이다. 이러한 분야에서 번역용어사전을 수작업으로 구축하는 것은 큰 부담이 된다. 본 논문에서는 이미 알고 있는 용어(원어)와 번역용어를 말뭉치에서 함께 표기한 부분을 찾아 패턴화하는 작업과, 생성된 패턴으로 추가의 용어-번역용어를 추출하는 작업을 반복하여 수행함으로써 번역용어사전을 자동으로 구축하는 방안을 제안한다. 인터넷 문서를 대상으로 본 제안방법을 적용해 본 결과 상당분량의 유효한 한글-영문용어들을 추출할 수 있었다.

### 1. 서론

전문용어의 가짓수가 많고 생성빈도 또한 높은 분야에서 고품질의 정보검색과 기계번역 결과를 얻기 위해서는 상당 분량의 번역용어사전의 확보가 필수적이다[1][2]. 예를 들어 정보검색 결과문서들을 군집화하여 사용자에게 제시하고자 할 때 번역용어사전이 구축되어 있지 않다면 ‘인공지능’에 대한 검색결과로 ‘Artificial Intelligence’라는 영문용어를 중심으로 하는 군집이 생성될 수 있다<sup>2</sup>. 하지만 이러한 번역용어사전을 광범위하게 수작업으로 구축하는 것은 큰 부담이 된다. 본 논문에서는 ‘이미 알고 있는 용어(원어)와 번역용어를 말뭉치에서 함께 표기한 부분을 찾아 패턴화하는 작업과, 생성된 패턴으로 추가의 용어-번역용어를 추출하는 작업을 반복하여 수행함으로써 번역용어사전을 자동으로 구축하는 방안을 제안한다.

본 연구와 관련된 기존연구로 괄호 안에 포함된 영문에 대응하는 한글대역어구(한글번역어구)의 범위를 인식하는 문제에 관한 연구가 있었다[3]. 이 연구에서 한글대역어구의 범위를 보다 정확히 파악하기 위하여 음운유사도와 복합어를 포함한 대역어 부분일치 방안을 병행하여 적용하였다. 본 논문에서 제안하는 방법이 기계번역의 측면에서 접근한 기존 연구와 다른 점은 정제된 말뭉치가 아닌 인터넷 상의 문서를 대상으로 하고 있다는 점과 괄호 이외에 다양한 형태로 나타날 수 있는 패턴들도 자동으로 생성하여 활용한다는 점이다. 또한, 기초사전의 도움 없이 사용자가 제시한 적은 수의 한글-영문용어 목록을 기반으로 패턴과 추가의 한글-영문용어를 생성하고 추출하는 방식은 데이터 마이닝[4]의 한 분야인 웹 마이닝[5] 측면에서의 접근이라는 데 그 차이가 있다.

이어지는 2장에서는 한글-영문 번역용어사전을 구축하는 방안을 설명하고, 3장에서는 인터넷 상의 문서를 대상으로 적용

할 때의 고려사항과 생성된 한글-영문용어의 적절성을 평가하는 척도에 대하여 기술하였다. 4장에서는 본 논문에서 제시한 방법을 실험결과와 함께 분석하고 마지막 5장에서 결론과 향후 연구를 정리하였다.

### 2. 한글-영문용어 추출

본 장에서는 접근하고자 하는 방식을 먼저 예를 들어 설명하고자 한다. 그림 1은 사용자가 (인공지능, Artificial Intelligence)라는 한글-영문용어를 기존에 알고 있다고 할 때, 이를 질의로 하여 인터넷 문서를 검색한 결과의 일부이다. 검색결과에서 질의로 주어진 용어가 나타난 부분은 기울인 글씨로 표기하였다.

1	인공지능 : <i>Artificial Intelligence</i> ... 따라서 인공지능은 공학적, 과학적 목표를 모두 가지고 있다 ... 인공지능의 연구 결과에 관심을 갖고 주시하는 사람들 중에는 최소한 네 가지 ... 인공지능이 직접적 연관성을 가지고 있는 또 하나의 분야는 심리학 (Psychology) 이다. ...
2	머신비전, 신경망에 관련된 종합정보 사이트 ... 머신비전, 신경망에 관련된 종합정보 사이트 - <a href="http://www.milab.co.kr">http://www.milab.co.kr</a> 머신비전(machine vision), 신경망(neural network), 인공지능(artificial intelligence), 유도무기 기술(guided-weapons technologies), 패턴인식(pattern recognition), ATR(automatic target recognition) ...
3	교수님 소개 ... 패턴 인식(Pattern Recognition). 자연어 처리(Natural Language Processing). 한국어 정보 처리(Korean Information Processing). 인공 지능(Artificial Intelligence). 학회활동. 한국정보과학회 중신회원. 한국 정보처리학회 정회원. 한국 인지과학회 정회원. ...

그림 1. ‘인공지능 artificial intelligence’ 검색결과와 일부

각각의 문서에서 질의로 주어진 한글-영문용어가 발견된 부분을 살펴보면 한글-영문용어의 표현형태가 서로간 유사한 경우가 많음을 알 수 있다. 따라서, 이러한 한글-영문용어의 표

<sup>1</sup> 국가지정연구실사업(과제명: 언어 중심의 지능적 정보처리를 위한 단계적 우리말 분석기술의 개발(M10203000028-02J0000-01510))의 지원을 받아 이루어진 것임.

<sup>2</sup> 현재 서비스되고 있는 클러스터링에 기반한 정보검색시스템에서 이러한 결과를 발견할 수 있다.

원형태를 패턴으로 생성하여 문서에 적용한다면, 추가적인 한글-영문용어를 추출할 수 있을 것이다. 예를 들어 문서3에서 '인공지능(Artificial Intelligence)'라는 구문을 발견할 수 있는데 이를 <접표><한글용어><작은괄호-염><영문용어><작은괄호-닫음>과 같이 패턴화시킬 수 있다. 이 패턴을 문서3에 적용하게 되면 (한국어 정보 처리, Korean Information Processing)과 같은 추가의 한글-영문용어를 추출할 수 있다.

패턴은 그 표현력에 따라 다양하게 정의가 가능하는데, 본 연구에서는 <선행 단어><용어1><가운데 단어들><용어2><후행 단어> 형태로 표현하였다. 표 1에는 그림 1에서 질의로 사용한 (인공지능, Artificial Intelligence)라는 한글-영문용어가 발견된 부분을 참고하여 생성한 패턴들을 보여주고 있다. 표 2는 생성된 패턴을 그림 1의 문서에 적용하여 추출할 수 있는 한글-영문용어들을 나열하였다.

표 1. 검색결과에서 생성된 패턴의 예

패턴	문서	선행	용어1	가운데	용어2	후행
1	1	$\emptyset^3$	<한글>	:	<영문>	$\emptyset$
2	2	,	<한글>	(	<영문>	)
3	3	.	<한글>	(	<영문>	)

표 2. 생성된 패턴을 적용하여 추출한 한글-영문용어의 예

패턴	문서	한글용어	영문용어
2	2	신경망	Neural Network
2	2	유도무기 기술	Guided-Weapons Technologies
2	2	패턴 인식	Pattern Recognition
3	3	패턴 인식 <sup>4</sup>	Pattern Recognition
3	3	자연어 처리	Natural Language Processing
3	3	한국어 정보 처리	Korean Information Processing




그림 2. 한글-영문용어 추출 흐름

<sup>3</sup> 제목이나 문서의 시작 또는 끝부분에는 <선행 단어>나 <후행 단어>가 없는 경우가 있다. 이러한 경우 해당 단어를  $\emptyset$ 로 표기하였다.

<sup>4</sup> 한글의 경우 '패턴 인식'과 '패턴인식'처럼 띄어쓰기가 다른 용어는 동일한 용어로 취급하였다. 영문은 대소문자 구분을 하지 않았다.

패턴을 생성하는 작업과 생성된 패턴으로 한글-영문용어를 추출하는 작업을 반복 수행하여, 번역용어사전을 구축하는 방안의 전반적인 작업흐름을 그림 2에 나타내었다.

### 3. 인터넷을 이용한 한글-영문용어 추출

앞에서 제시한 접근방법은 논문모음과 같이 정제된 말뭉치에는 그 적용이 용이하지만, 인터넷 상의 문서를 대상으로 적용하고자 하는 경우에는 다음의 두 가지 사항을 고려하여야 한다. 첫째로는 대부분의 검색시스템은 시스템 부하 등을 이유로 패턴형태의 질의를 허용하지 않는다는 점이다. 둘째로는 인터넷 문서는 오타의 발생빈도가 높은 편인데, 그 결과로 잘못된 한글-영문용어가 추출될 수 있다는 점이다.

패턴으로 검색이 허용되지 않는 경우에는 한글-영문용어 추출을 위한 문서로 인터넷 검색시스템의 검색결과를 활용할 수 있다. 구체적인 방법은 알고리즘 1에 기술하였다.

1.  $P^* \leftarrow \emptyset, R \leftarrow \emptyset, L \leftarrow \emptyset$
2. 적은 수의 한글-영문용어목록 P를 미리 제공한다.
3. P가 공집합이 아니면, 하나의 한글-영문용어 p를 골라 인터넷 검색엔진의 질의로 변환하여 검색한다.  $P \leftarrow P - \{p\}$ ,  $P^* \leftarrow P^* \cup \{p\}$ , 검색결과 D를 검색결과 모음 L에 추가한다.
4. D에서 p가 발견된 부분으로 찾아 패턴을 생성하고, 생성된 신규패턴은 R에 추가한다.
5. 신규패턴은 L를, 기존패턴은 D를 대상으로 패턴을 적용하여 추가의 한글-영문용어목록을 추출하고 이를 P에 추가한다.
6. 더 이상 추가의 한글-영문용어와 패턴이 발견되지 않을 때까지 3-5의 과정을 반복한다.
7. P\*의 한글-영문용어를 선호도에 따라 정렬하여 출력한다.

알고리즘 1. 인터넷을 활용한 한글-영문용어 추출 알고리즘

문서 내에서 한글-영문용어 관련 부분에 오타가 있거나, 잘못된 패턴이 있는 경우 해당 용어와 부적절한 번역용어가 짝을 이루는 결과가 발생할 수 있다. 이러한 문제를 해결하기 위해서는 추출한 한글-영문용어의 적절성을 평가할 수 있어야 한다. 본 연구에서는 표 3의 가정에 기반하여 한글-영문용어의 적절성을 추정하고자 하였다.

표 3. 적절한 한글-영문용어에 대한 가정

1. 빈번하게 발생한다.
2. 다양한 패턴에 의하여 지원된다.
3. 각각의 용어는 연관된 번역용어 중에서 비중이 높다.

위의 가정에 기반하여 한글-영문용어  $p_m$ 의 적절성  $w(p_m)$ 은 수식 1과 같이 추정할 수 있다. N은 발견된 한글-영문용어의 총 횟수이며,  $\text{support}(r_i, p_m)$ 은 용어  $k_m$ 과  $e_m$ 으로 이루어진 한글-영문용어  $p_m$ 이 패턴  $r_i$ 에 의하여 발견된 횟수이다.  $P(p_m|k_m)$ 은  $k_m$ 이 포함된 한글-영문용어 중에서  $p_m$ 이 발생한 비율이다.

$$w(p_m) = P(p_m|k_m)P(p_m|e_m) \times \left( - \sum_{r \in R} \frac{\text{support}(r_i, p_m)}{N} \log_2 \left( \frac{\text{support}(r_i, p_m)}{N} \right) \right)$$

수식 1. 한글-영문용어의 적절성 추정

4. 실험결과 및 분석

이상에서 제안한 접근 방법의 유효성을 확인하기 위하여 다음과 같은 조건으로 실험하였다. 먼저 최초 한글-영문용어 목록으로 하나의 용어 (기계학습, Machine Learning)을 사용하였다. 인접한 한글과 영문은 띄어 쓴 것으로 간주하였고 괄호, 콜론과 같은 기호는 한 글자씩을 단어로 취급하였다. <선행 단어>와 <후행 단어>는 최대 1단어로 제한하였으며, <가운데 단어>의 수는 최소 1단어, 최대 3단어로 제약하였다. <영문용어>의 좌우로는 영문이 나타날 수 없으며, <한글용어>와 <영문용어>는 각각 최소 2자, 5자 이상으로 제한을 두었다. <한글용어>와 <영문용어>는 최대 3단어까지의 개수차이를 허용하였다. 인터넷 검색 시스템으로는 Google[6]을 이용하였다. 검색결과 상위 100건 문서까지 패턴 생성과 용어추출을 위한 대상 문서로 활용하되 개별 페이지에 직접 접근하지 않고 검색시스템이 제공한 검색결과 페이지만을 이용하였다.

표 4에는 총 3,300건의 한글-영문용어 검색을 수행하여 추출한 한글-영문용어들을 수식 1의 적절성 평가 기준에 따라 정렬한 결과의 일부분을 보여주고 있다. 전문용어 이외에도 일반적인 용어나 회사 또는 인물에 대한 고유명사, 영문약어 등도 상당수 추출되었다. 표 5에는 생성된 총 1,840개의 패턴들을 수식 1에서  $P(p_m|k_m)$ 항과  $P(p_m|e_m)$ 항을 제외한 평가기준 즉, 다양한 한글-영문용어를 지원하는 패턴을 우선시하여 적절성을 평가한 결과의 일부분을 보여주고 있다. 이 중에서 작은 괄호를 포함한 패턴은 1,495개였다.

표 4. 인터넷 문서에서 추출한 한글-영문용어의 예

적절성순위	한글용어	영문용어
1	패러다임	Paradigm
2	야마하	Yamaha
4	인공지능	Artificial Intelligence
5	다형성	Polymorphism
9	한국과학기술정보연구원	KISTI
10	시스코 시스템즈	Cisco Systems
11	자막 <sup>5</sup>	English
26	하이데거	Heidegger
604	최저임금제	Minimum-Wage Laws

표 5. 인터넷 문서에서 생성된 패턴의 예

적절성순위	선행	용어1	가운데	용어2	후행
1	∅	<한글>	(	<영문>	)
2	.	<한글>	(	<영문>	)
6	)	<한글>	(	<영문>	)
7	의	<한글>	(	<영문>	)
18	∅	<영문>	-	<한글>	∅
19	(	<영문>	):	<한글>	∅
47	∅	<영문>	/	<한글>	∅
54	∅	<한글>	[	<영문>	]
157	새로운	<한글>	(	<영문>	)

<sup>5</sup> 이러한 한글-영문용어가 생성된 이유는 DVD 관련 사이트에서 제품 설명에 '자막 : English'와 같은 내용이 포함되기 때문이었다.

그림 3은 추출한 한글-영문용어들이 유효한지 자세히 평가하기 위하여 시스템이 제시한 상위 1,000개의 한글-영문용어들을 대상으로 실제 일치 여부를 수작업으로 확인한 결과이다.<sup>6</sup> 최초 한글-영문용어를 단 하나만 제시하였으며 사전과 같은 언어적 정보는 사용하지 않는다는 점을 감안한다면 1,000개의 용어 중 85% 이상의 정확도는 상당한 것으로 평가할 수 있다. 순위가 내려갈수록 정확도는 조금씩 저하되는데 이는 <한글용어><나누기기호><영문용어>와 같이 발생빈도가 높으면서 오류발생 가능성 또한 높은 패턴에 의한 것으로 추정된다.




그림 3. 추출한 한글-영문용어들의 적절성에 따른 정확도

5. 결론 및 향후 연구

이상으로 적은 수의 한글-영문용어에 기초하여 유효한 한글-영문용어를 다량 추출할 수 있는 가능성을 실험적으로 확인하였다. 향후 패턴의 정확도와 언어적 정보를 반영하여 한글-영문용어를 보다 면밀하게 평가할 수 있는 방안과 사용자가 특정 용어에 대한 번역용어를 문의하였을 때 이를 효율적으로 처리할 수 있는 방안에 대한 연구가 요청된다.

참고문헌

- [1] Hull, D. and Grefenstette, G. "Querying Across Languages: A Dictionary-based Approach to Multilingual Information Retrieval". In *Proceedings of the 19th Annual international ACM SIGIR 1996*, Zurich, Switzerland, pp. 49-57, 1996.
- [2] Sheridan, P. and Ballerini, J. P., "Experiments in Multilingual Information Retrieval using the SPIDER System", In *Proceedings of the 19th ACM SIGIR Conference on Research and Development in Information Retrieval*, Zurich, Switzerland, pp. 58-65.
- [3] 이재성, 서영훈, "한영 혼용문에서 괄호 안 대역어구의 자동 인식," *한국정보처리학회논문지* 제9-B권 제 4호, 2002. 8, pp. 445-452.
- [4] Witten, I. H. and Frank, E., *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Morgan Kaufmann, 2000.
- [5] Kosala, R. and Blockeel, H., "Web mining research: A survey", *SIGKDD Explorations*, Vol. 2, Num. 1, pp. 1-15, 2000.
- [6] Google, <http://www.google.co.kr>

<sup>6</sup> 복수의 번역용어가 존재하는 경우 이들 모두 올바른 것으로 처리하였다. 이러한 예로 '클러스터'와 '군집'이 혼용되는 경우를 들 수 있다.