

문장구조 유사도와 단어 유사도를 이용한 클러스터링 기반의 통계기계번역

(Clustering-based Statistical Machine Translation Using
Syntactic Structure and Word Similarity)

김 한 경 ^{*} 나 휘 동 ^{**} 이 금희 ^{**} 이 종 혁 ^{***}
(Hankyong Kim) (Hwidong Na) (Jin-Ji Li) (Jong-Hyeok Lee)

요약 통계기계번역에서 번역성능의 향상을 위해서 문장의 유형이나 장르에 따라 클러스터링을 수행하여 도메인에 특화된 번역을 시도하는 방법이 있다. 그러나 기존의 연구 중 문장의 유형 정보와 장르에 따른 정보를 동시에 사용한 경우는 없었다. 본 논문에서는 각 문장의 문법적 구조 유사도에 따른 유형별 분류 기법과, 단어 유사도 정보를 사용한 장르 구분법을 적용하여 기존의 두 기법을 통합하였다. 이렇게 분류된 말뭉치에서 추출한 도메인 특화 모델과 전체 말뭉치에서 추출된 모델에서 보간법(interpolation)을 사용하여 통계기계번역의 성능을 향상하였다. 문장구조 유사도와 단어 유사도의 계산 방법으로는 각각 커널과 코사인 유사도를 적용하였으며, 두 유사도를 적용하여 말뭉치를 분류하는 과정에서는 K-Means 알고리즘과 유사한 기계학습 기법을 사용하였다. 이를 일본어-영어의 특허문서에서 실험한 결과 최선의 경우 약 2.5%의 상대적인 성능 향상을 얻었다.

키워드 : 통계기계번역, 클러스터링, 도메인 특화 모델, 문장구조 유사도, 단어 유사도

Abstract Clustering method which based on sentence type or document genre is a technique used to improve translation quality of SMT(statistical machine translation) by domain-specific translation. But there is no previous research using sentence type and document genre information simultaneously. In this paper, we suggest an integrated clustering method that classifying sentence type by syntactic structure similarity and document genre by word similarity information. We interpolated domain-specific models from clusters with general models to improve translation quality of SMT system. Kernel function and cosine measures are applied to calculate structural similarity and word similarity. With these similarities, we used machine learning algorithms similar to K-means to clustering. In Japanese-English patent translation corpus, we got 2.5% point relative improvements of translation quality at optimal case.

Key words : SMT(Statistical Machine Translation), Clustering, Domain-specific model, Syntactic Structural similarity, word similarity

· 이 논문은 2009 한글 및 한국어 정보처리 학술대회에서 '문장구조 유사도와 단어 유사도를 이용한 클러스터링 기반의 통계기계번역'의 제목으로 발표된 논문을 확장한 것임

^{*} 비 회원 : 포항공과대학교 정보처리학과
arch@postech.ac.kr

^{**} 비 회원 : 포항공과대학교 컴퓨터공학과
leona@postech.ac.kr
ljh@postech.ac.kr

^{***} 종신회원 : 포항공과대학교 컴퓨터공학과 교수
jhlee@postech.ac.kr
논문접수 : 2009년 11월 12일
심사완료 : 2010년 2월 2일

Copyright©2010 한국정보과학회 : 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다. 정보과학회논문지: 소프트웨어 및 응용 제37권 제4호(2010.4)

1. 서 론

통계기계번역(statistical machine translation, SMT) 시스템은 언어모델, 번역모델의 확률모델을 사용하여 번역을 수행한다. 이 번역시스템의 번역성능을 높이기 위한 방법의 하나로 보간법을 사용하여 도메인에 특화된 모델을 추가로 사용하는 연구가 진행되어 왔다. 보간법을 모델에 적용하는 방법은 전체 말뭉치에서 획득한 모델의 각 확률을 특화된 모델의 해당 값을 참조하여 수정하는 것이다. 이러한 기법을 사용한 기존연구들은 말뭉치를 분류하는 기준에 따라 문장의 유형에 따라 나누는 방법과 문서의 장르에 따라 나누는 방법의 두 가지로 정리할 수 있다. 본 논문에서는 각각 고유한 장점을

가진 두 방법을 통합하여 말뭉치를 분류하고 통계기계 번역 시스템의 번역성능을 높이는 실험을 수행하였다.

통계기계번역에서 혼히 사용하는 언어모델은 n-gram 어순에 따라 계산되며, 이는 의문문, 평서문 등 문장 유형에 따라서 다른 결과를 가진다. 따라서 문장유형에 따라 말뭉치를 분류하게 되면 유형별 어순의 특성이 각각의 언어모델에 반영된다. 문장의 유형에 따라 특화된 번역을 수행한 기존연구들은 이러한 사실에 기반을 두고 실험을 수행하였다. 한편 문서의 장르에 따라 말뭉치를 분류한 기존연구의 경우 문서의 장르에 따라서 원시언어와 대상언어 사이의 적합한 대역어가 다를 수 있다는 것을 근거로 하고 있다. 중의성을 가진 어휘는 여러 대역어를 가질 수 있고, 문서의 장르에 따라 분류된 말뭉치에서 획득한 번역모델은 대역어의 확률이 해당 도메인에 특화된 값을 가지게 된다.

본 논문에서는 문법적 구조의 유사도를 계산하여 문장의 유형을 판단하는 방법을 제안하였고, 단어 유사도를 계산하여 장르를 추정하는 방법을 통합하여 말뭉치를 분류하였다. 이 두 유사도를 사용한 말뭉치의 분류방법은 K-means와 유사한 비지도 기계학습(unsupervised machine learning)기법을 사용하였다. 이는 문장 유형의 구분에서 말뭉치의 특성에 관계없이 일반적으로 적용이 가능한 장점이 있으며, 문서의 장르별 구분을 사용한 기존연구에서 발견한 단점을 또한 해결하였다.

본 논문에서는 말뭉치의 분류작업 후, 각 클러스터에서 획득한 도메인 특화 모델을 통계기계번역 시스템에 추가로 사용하였다. 이는 선형보간법을 사용하여 전체 훈련말뭉치에서 획득한 모델과 도메인 특화 모델을 통합하여 통계기계번역 시스템에 사용하는 것으로 구현하였다. 이 실험결과와 비교하기 위한 베이스라인 시스템은 전체 훈련말뭉치에서 추출한 언어모델과 번역모델만을 사용하였다. 본 논문에서 수행한 실험은 특허번역문서 말뭉치에서 일본어-영어의 방향으로 번역하였으며 베이스라인의 번역결과와, 도메인 특화 모델을 추가로 사용한 번역결과를 비교하였다.

2. 기준 연구

도메인에 특화된 번역을 시도한 기존연구들에서는 훈련말뭉치를 분류하는 기준으로 의문문, 평서문 등의 문장유형을 이용하거나, 뉴스, 비평 등 장르를 사용하였다. 문장유형에 따라 분류한 기존연구에서는 문장유형을 특정하기 위해서 말뭉치의 특성에 의존적인 방법을 사용하거나 특정유형에만 적용이 가능한 단점이 있다. 기존 연구 중에는 이러한 문제를 해결하기 위한 시도가 있었으나 그 경우에는 문장유형에 따른 분류 과정에서 문법적 정보가 사용되지 않았다. 한편, 장르에 따라 훈련말

뭉치를 분류한 기준연구에서는 사전에 장르별로 나누어 구축한 훈련말뭉치를 사용하였을 경우에 적용 가능한 한 기법이거나, 번역할 원시언어 문장의 적합한 장르를 판단하는 도메인 예측과정에서 문제가 있었다.

말뭉치를 문장유형에 따라 분류한 기법의 연구들은 문장유형에 따른 어순의 특성을 언어모델에 반영하며 이를 번역성능의 향상에 이용한다. [1]은 훈련말뭉치를 정규식을 이용하여 의문문, 명령문, 단순 나열과 같은 10여 개의 클러스터로 분류였다. 그리고 이들에서 각 도메인에 특화된 언어모델을 획득하여 보간법을 적용한 결과 상당한 복잡도의 감소를 얻었으며, 향상된 번역결과를 얻었다. 하지만 이 실험에서 사용한 정규식은 훈련 말뭉치의 일부에만 적용되며, 말뭉치의 특성에 따른 휴리스틱을 사용하기 때문에 일반적으로 확장하기에 곤란한 단점이 있다.

[2]는 간접적인 접근방법을 사용하여 이러한 문제를 해결하였다. 이들은 문장을 직접 분석하여 분류하지 않고 각 클러스터의 언어모델에 적합한 문장을 해당 클러스터에 배치하는 방법으로 말뭉치를 분류하였다. 이는 훈련말뭉치를 임의로 나누고 각 유형별 말뭉치에 대하여 해당 언어모델로 계산한 엔트로피의 값이 낮아지도록 문장의 재배치를 반복하는 기계학습 기법으로 수행되었다. 이 방법은 정규식을 적용하는 것과는 달리 말뭉치의 특성에 대하여 독립적이며, 모든 문장을 분류할 수 있는 장점이 있다. 하지만 분류과정에서 어떠한 문법적인 정보도 사용되지 않기 때문에 문장유형에 따른 분류가 이루어진다고 확신할 수 없다.

한편 [3]은 확률적 분류기를 사용하여 훈련말뭉치를 의문문과 평서문 두 부류로 나누어 도메인 특화 모델을 획득하고, 분류기의 확률을 사용하는 동적 보간법을 제안하였다. 이는 번역할 대상 원시언어 문장이 각각의 도메인에 속할 확률을 해당 도메인 모델이 보간법에서 가지는 비율로 사용하는 기법이다. 하지만 이 또한 분류기가 $n \leq 3$ 인 n-gram 정보만을 사용하기 때문에 문장의 문법적 구조정보를 사용하는 데 한계가 있다.

문장의 문법적 정보를 충실히 사용한 경우는 [4]가 있다. 이는 통계기계번역에 해당하는 연구는 아니지만 특허번역에서 형태소분석 결과와 구문분석 결과 등 문법적 정보와 공기정보 등의 문맥까지 고려하여 도메인에 특화된 번역을 시도하였다. 이 연구에서는 구문/문장에 특화를 수행하는 것과 특허의 의료위생, 기계 등 내용에 따른 특화를 함께 수행하였다. 세부 구현에서는 전문 번역가의 번역 결과를 사용하는 수동 구축과 기존의 사전 정보에서 출발하는 반자동 감수 등을 사용하므로 다른 말뭉치에 적용하기에 곤란한 방법으로 해당 연구에서는 구축 비용과 시간의 제약이 있음을 역시 밝히고 있다.

통계기계번역의 기준연구에서 [4]의 사용한 방법 중 하나인 문서의 장르에 따른 도메인 특화를 시도하는 기법으로는 훈련말뭉치를 문서의 장르에 따라 나누는 것이다. 이는 주로 훈련말뭉치가 여러 장르의 문서로 이루어진 경우, 각각에 특화된 번역을 수행하여 그 성능을 향상시키기 위해서 사용한다. 이러한 기준 연구로 [5]는 국제특허분류기준(International patent classification, IPC)에 따라 특허번역 말뭉치를 분류하고 각 세부 도메인에 획득한 도메인 특화 모델을 보간법에 사용하였다.

[6]은 [5]와 동일한 특허번역 말뭉치에서 정보검색 기법을 사용하는 분류기를 사용하였다. 이 분류기는 코사인 계수를 이용하여 단어 유사도를 측정하여 분류하였다. 이들은 도메인 예측 과정에서 번역할 문장에 적합한 세부 도메인을 선택하지 못하는 단점이 있었으나, 각 문장에 가장 알맞은 도메인 특화 모델을 사람이 직접 결정하여 적용한 실험에서는 상당한 번역성능의 향상을 얻었다.

[7]은 비평, 연설, 방송, 뉴스 등 여러 장르로 이루어진 말뭉치에서 다양한 유사도 측정기법을 사용하였으며 선형보간법과 지수선형보간법의 결과를 비교하였다. 이들은 다양한 방법을 사용하여 각 장르별 모델을 조합하여 훈련말뭉치에 해당하지 않는 장르의 문서를 번역하는 효과적인 방법을 제안하였다. 그러나 이러한 방법을 사용하기 위해서는 훈련말뭉치가 사전에 여러 장르로 나누어져 있는 상태여야 하는 단점이 있다.

3. 방법론 개요

본 논문에서 제안하는 방법은 크게 두 단계로 이루어진다. 하나는 훈련말뭉치를 유형별로 분류하는 단계이다. 이를 위하여 문장의 문법적 구조 유사도를 의존관계 트리에서 커널 합수를 사용하여 계산하였고, 단어 유사도를 코사인 유사도를 적용하여 계산하였다. 훈련말뭉치의 분류는 K-Means와 유사한 비지도 기계학습 알고리즘으로 수행한다. 이 알고리즘에서 사용하는 거리합수는 문장구조 유사도와 단어유사도를 일정한 비율로 합산하여 계산한다.

다음은 유형별로 특화된 번역을 수행하는 단계이다. 이는 각각의 도메인 특화 모델의 획득과 이를 추가로 사용하는 통계기계번역 시스템의 구축, 그리고 번역할 원시언어 문장의 도메인을 예측하여 해당 도메인에 특화된 시스템에서 번역을 수행하는 것으로 이루어진다.

아래에서는 각 단계별로 차안점과 수행 방안을 설명하였다.

3.1 문장구조 유사도의 계산

두 원시언어 문장간의 문장구조 유사도는 일본어의 의존관계 트리에서 커널 합수를 사용하여 계산한 값을

사용하였다. 본 논문에서 사용한 커널함수는 [8]이 제안한 두 의존관계 트리간의 유사도를 측정하는 기법으로, 이를 사용하여 문장구조 유사도를 계산하는 과정에서 일본어 의존관계 트리의 특성에 의해 일부 수정된 사항이 있어 다음과 같이 정리하였다.

3.1.1 일본어 의존관계 트리

본 논문에서는 일본어 의존관계 파서인 [9]를 사용하여 의존관계 트리를 획득하였다. 이 의존관계 트리는 일본어의 의미단위인 문절(bunsetsu)을 노드로 사용한다. 문절에는 형태소분석 결과와 각 형태소의 품사가 포함되어 있으며 어간형태소의 정보 또한 표시되어 있다. 그러나 트리의 노드에 해당하는 각 문절 사이에 관계표지가 없이 지배소-의존소 관계만이 표시된다. 이러한 일본어 의존관계 트리에서 문장구조 유사도를 계산함에 있어서 별도로 계산할 단어 유사도와 중복을 피하고, 문절에서 문장의 구조를 나타내는 정보만을 추출하기 위해서 첫 어간형태소의 품사와 이후의 형태소를 연결한 것을 문절의 품사로 정의하였고, 그 예는 그림 1에 정리한 바와 같다.

문절의 품사를 이와 같이 정의하였을 때, 첫 번째 어간형태소의 품사는 문절의 문법적 특성을 추정하는 데

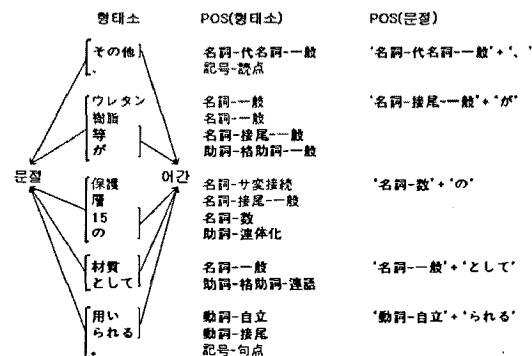


그림 1 일본어 문절의 품사 추출 예

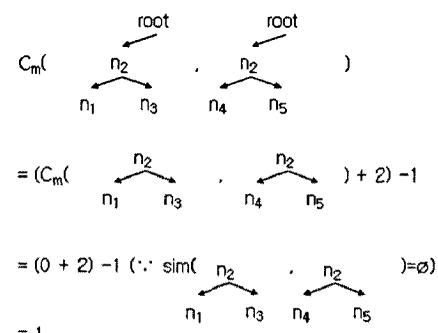


그림 2 수정된 $C_m(n_1, n_2)$ 에 적용되는 예

사용된다. 이후의 형태소들은 지배소-의존소 사이의 관계표지를 대신하여 해당 문절과 다른 문절이 서로 어떤 관계로 연결되었는지 추론하기 위한 자료이다.

이후의 실험에서는 일본어 의존관계 트리에서 지배소-의존소 관계와 본 논문에서 정의한 문절의 품사를 문장구조의 유사도를 계산할 정보로 사용한다.

3.1.2 의존관계 트리에서 커널 합수의 계산

상기한 바와 같이, 본 논문에서는 [8]이 제안한 "A Kernel for Dependency Structure"를 적용하여 문장구조의 유사도를 계산하였다. 그러나 커널 합수를 계산할 때 사용할 정보가 해당 논문에서 예제로 사용된 영어의 의존관계 트리와는 다르기에 관계표지 정보를 사용한 부분을 삭제하였고, 각 노드의 형태소를 사용한 부분을 문절의 품사를 사용하도록 수정하였다.

다음으로 이들이 제안한 커널함수는 두 트리에서 공통으로 가지는 서브트리의 수를 이용하여 계산한다. 그러나 공통의존소가 없을 때 공통서브트리의 수가 0이 아닌 -1로 계산되는 오류가 있어 그림 2와 같이 정상적인 값을 가지도록 수정하였다.

두 의존관계 트리 d_1, d_2 의 커널 합수 $K(d_1, d_2)$ 는 각 트리에서 노드의 핍합이 N_1, N_2 이고, 그 원소인 문절 n_1, n_2 가 가지는 공통서브트리의 수를 $C_m(n_1, n_2)$ 라 정의 할 때 아래와 같이 계산된다.

$$K(d_1, d_2) = \sum_{n_1 \in N_1, n_2 \in N_2} C_m(n_1, n_2) \quad (1)$$

이 때 $C_m(n_1, n_2)$ 은 다음의 식을 만족하는 n_1, n_2 의 공통의존소 $sim(n_1, n_2)$ 을 사용하여 계산할 수 있다.

$$sim(n_1, n_2) = \left\{ (x, y) \mid \begin{array}{l} x \in children(n_1), \\ y \in children(n_2), \\ POS(x) = POS(y) \end{array} \right\} \quad (2)$$

이 $sim(n_1, n_2)$ 에서 $C_m(n_1, n_2)$ 은 조건에 따라서 아래의 식 (3)과 같이 계산할 수 있다.

$$\begin{aligned} & \text{if } POS(n_1) \neq POS(n_2) \text{ or } children(n_1) = \emptyset \\ & \quad \text{or } children(n_2) = \emptyset \text{ or } sim(n_1, n_2) = \emptyset \\ & \text{then } C_m(n_1, n_2) = 0 \\ & \text{else } C_m(n_1, n_2) = \prod_{(x, y) \in sim(n_1, n_2)} (C_m(n_1, n_2) + 2) - 1 \end{aligned} \quad (3)$$

상기의 식을 통하여 계산한 커널함수의 값은 두 의존관계 트리에서 공통으로 가지는 서브트리의 수가 일치하면 전체 트리의 크기와 관계없이 일정한 값을 가진다. 따라서 문장구조의 유사도를 올바르게 나타내기 위해서 이 값을 두 트리의 크기로 정규화 하여 사용하였으며, 이 문장구조 유사도 $Structure(d_1, d_2)$ 의 값은 다음과 같다.

$$Structure(d_1, d_2) = \frac{K(d_1, d_2)}{|N_1| + |N_2|} \quad (4)$$

3.2 단어 유사도의 계산

두 원시언어 문장 사이의 단어 유사도를 계산하기 위해서 [9]의 일본어 문장 구문분석 결과에서 형태소 분석 정보를 추출하여 사용하였다. 계산 방법으로는 코사인 유사도의 계산기법을 적용하였다. 코사인 유사도는 두 벡터의 내적을 사용하여 유사도를 계산하므로, 각 문장의 형태소 분석 정보를 가공하여 1-gram 단어 빈도수의 벡터로 변환하여 코사인 유사도를 계산하였다.

즉 두 문장 S_1, S_2 에서 이들에 포함된 형태소를 bag of word 모델로 사용하여 벡터의 차원을 결정하고, 각 문장에서 형태소의 빈도수를 해당 차원에 표시하여 벡터로 변환한다. 이러한 방법을 사용하여 두 문장 S_1, S_2 은 각각 단어 빈도수의 벡터 V_1, V_2 로 표현할 수 있다. 따라서 두 문장 S_1, S_2 에서 코사인 유사도의 값은 아래의 식에 대입하여 얻을 수 있다.

$$Word(S_1, S_2) = \cos(\theta) = \frac{V_1 \cdot V_2}{|V_1| \times |V_2|} \quad (5)$$

이때 벡터 V_1, V_2 를 구성하는 단어 빈도수는 각 문장에서 형태소의 출현 횟수를 사용하여 계산하므로 항상 0 이상의 값을 가진다. 따라서 두 문장의 단어 유사도는 항상 $0 \leq Word(S_1, S_2) \leq 1$ 을 만족한다.

3.3 분류 알고리즘

분류 알고리즘에서 사용할 거리함수(distance function)는 3.1과 3.2에서 정의한 $Structure(d_1, d_2)$ 와 $Word(S_1, S_2)$ 를 다음과 같이 일정한 비율로 더하여 계산한다.

$$D(S_1, S_2) = \alpha \times Structure(d_1, d_2) + (1-\alpha) \times Word(S_1, S_2) \quad (6)$$

따라서 이 거리함수의 값이 클수록 두 문장은 더 높은 유사도를 가진다. 아래에서는 이 거리함수를 사용한 기본 분류 알고리즘과 분류기, 분류기를 이용하여 처리 속도를 향상한 개선된 알고리즘을 제안하였다.

3.3.1 기본 분류 알고리즘

기본 분류 알고리즘은 K-Means 알고리즘과 유사한 기법으로 [2]가 언어모델을 사용하여 말뭉치를 분류한 방법과 같이 훈련말뭉치를 사용자가 지정한 수만큼의 클러스터로 분류한다. 이는 비지도 기계학습으로, 분류할 클러스터의 수와 거리함수에서 사용할 유사도 간의 비중을 제외하면 모든 정보를 말뭉치에서 학습한다.

이 알고리즘의 수행 과정에서 여러 문장이 포함된 클러스터와 분류할 문장 사이의 유사도를 측정할 필요성이 있다. 그러나 식 (6)에서 정의한 거리함수는 두 문장 사이의 쌍대비교(pair wise comparison)만이 가능하므로 문장과 클러스터 간의 거리는 아래의 식과 같이 대상 문장과 해당 도메인에 속한 모든 문장과의 거리의 평균을 사용한다.

$$D(S, C) = \frac{\sum_{S_i \in C} D(S, S_i)}{|C|} \quad (7)$$

기본 분류 알고리즘의 동작은 다음과 같다:

단계 1. 훈련말뭉치의 모든 문장 쌍에 대하여 거리합수를 계산하고 그 값을 저장한다.

단계 2. 훈련말뭉치의 문장을 사용자에 의해 정해진 수의 클러스터로 임의로 배정한다.

단계 3. 훈련말뭉치의 각 문장에 대하여, 해당 문장과 모든 클러스터 사이의 거리합수 값을 계산한다.

단계 4. 각 문장을 $C' = \operatorname{argmax}_{c \in C} D(S, c)$ 와 같이 해당 문장과 거리합수의 값이 가장 큰 클러스터로 재배치한다.

단계 5. 단계 4에서 기존 소속과 다른 클러스터로 재배치되는 문장의 수가 일정 이하가 될 때까지 단계 3과 단계 4를 반복한다.

3.3.2 분류기

기본 분류 알고리즘에서 사용한 거리합수를 응용하여 대상 원시언어 문장이 훈련말뭉치의 클러스터 중 어느 클러스터와 가장 유사도가 높은지 판별하는 분류기를 만들 수 있다. 이는 대상 원시언어 문장 S 와 3.3.1의 기본 분류 알고리즘에서 분류한 클러스터의 집합 C 에서 $C' = \operatorname{argmax}_{c \in C} D(S, c)$ 를 만족하는 최적의 클러스터 C' 을 선택하는 것으로 기본 분류 알고리즘의 단계 3과 단계 4를 적용하여 수행할 수 있다.

3.3.3 개선된 분류 알고리즘

기본 분류 알고리즘에서는 훈련말뭉치에 속한 모든 문장 쌍에 대한 거리합수를 계산한다. 복잡도로 표현하면 문장수 n 에 대하여 $O(n^2)$ 과 같다. 본 논문에서는 이와 같은 기존 분류 알고리즘의 시간 복잡도를 개선하기 위해 분류기를 이용한 개선된 분류 알고리즘을 제안한다. 개선된 분류 알고리즘에서는 클러스터링 과정에서 충분한 양의 문장을 사용하면 그 결과를 사용하는 분류기의 정확도를 신뢰할 수 있다는 가정을 전제로 한다. 이러한 가정 하에 훈련말뭉치에서 일부를 시드 말뭉치로 선택하여 기본 분류 알고리즘을 수행하고 나머지 부분은 분류기를 이용하여 각 문장에 가장 알맞은 클러스터로 배치한다. 이렇게 기본 분류 알고리즘과 분류기를 사용하는 개선된 분류 알고리즘의 세부 동작은 다음과 같이 정리할 수 있다:

단계 1. 훈련말뭉치에서 충분한 양의 문장을 시드 말뭉치로 선택하여 기본 분류 알고리즘을 수행한다.

단계 2. 훈련말뭉치에서 시드로 선택되지 않은 여분의 문장들과 선택된 문장들 간의 거리합수를 계산한다.

단계 3. 단계 1에서 실행한 기본 분류 알고리즘이 완료되면 분류되지 않은 여분의 문장들을 분류기를 사용하여 적합한 클러스터에 배치한다.

단계 4. 기본 분류 알고리즘으로 나누어진 클러스터와 단계 3에서 분류기를 통하여 배치된 문장들을 통합하여 클러스터를 재구성한다.

이 개선된 분류 알고리즘의 복잡도는 시드로 선택된 부분의 문장을 x 라 하면 기본 알고리즘 부분에서 $O(x^2)$, 나머지 문장을 분류기를 사용하여 분류하는 과정에서 $O(xn)$ 으로 알고리즘 전체에서는 $O(x^2) + O(xn)$ 이 된다. 따라서 훈련말뭉치에서 시드로 선택하는 $x \ll n$ 부분이 일 경우 실질적인 복잡도는 $O(n)$ 으로 감소된다.

3.4 도메인 특화 번역

훈련말뭉치의 분류가 완료되면 클러스터로 나누어진 훈련말뭉치에서 언어모델과 번역모델을 획득하고 전체 훈련말뭉치에서 획득한 모델과 각 클러스터에서 추출된 도메인 특화 모델을 사용하는 번역 시스템을 구축한다. 이 시스템은 그림 3과 같이 선형 보간법을 적용하여 도메인 특화 모델과 전체모델을 함께 사용한다.

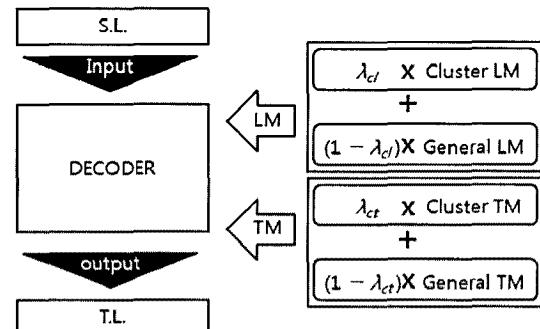


그림 3 도메인 특화 모델을 사용하는 시스템 개괄

보간법의 적용 과정에서는 언어모델과 번역모델 각각에 대하여 별도의 비율을 사용하였다. 훈련말뭉치 및 테스트말뭉치와는 별도의 말뭉치를 준비하여 전체 훈련말뭉치에서 학습한 모델과 도메인에 특화된 모델 사이의 비율을 학습하기 위하여 사용하였다. 그리고 이러한 학습을 거치지 않고 최선의 성능을 발휘하도록 임의로 조정한 비율을 적용하였을 경우의 결과도 함께 정리하였다.

상기한 바와 같이 각 클러스터에 대하여 특화된 번역 시스템을 구축한 이후에는 번역할 원시언어 문장마다 각각에 적합한 도메인을 예측하는 작업을 수행한다. 이는 3.3.2에서 서술한 분류기를 사용하여 해당 문장이 훈련말뭉치의 클러스터 중 어디에 가장 유사한지 판단하는 것으로 수행한다.

따라서 전체 테스트말뭉치의 번역결과는 테스트 말뭉치를 분류기로 나누어 각각의 문장에 해당하는 클러스터의 번역 시스템에서 번역을 수행하고 이 결과를 다시 취합하여 얻게 된다.

4. 실험

본 논문에서는 [10]에서 일본어-영어의 번역 방향을

선택하여 실험을 수행하였다. 언어모델과 번역모델은 [11]과 [12]를 이용하여 획득하였다. 베이스라인 번역시스템의 구축은 [13]을 [14]에서 제안한 방법에 따라 환경변수를 보정하여 사용하였다. 번역성능은 [15]를 사용하여 비교하였다.

4.1 말뭉치

실험에 사용한 말뭉치는 [10]으로 특허번역작업 말뭉치이다. 이는 실질적으로 평서문만으로 구성되어 있어 기존연구의 기법으로는 문장유형에 따른 분류를 수행하기에 적합하지 않다. 또한 [5]와 [6]의 기준연구에서 장르별 분류를 수행한 실험과 동일한 말뭉치로, 특히 단어 유사도를 사용하여 분류를 실행한 [5]의 실험 결과와는 세부 구현과정에서 차이가 있으나 간접적인 비교가 가능하다.

이 말뭉치에서 편의상 10만 문장을 임의로 선택하여 훈련말뭉치로 사용하였다. 그리고 이 훈련말뭉치와는 별도로 609문장을 준비하여 번역도구의 환경변수를 보정하기 위해서 사용하였으며, 선형보간법에서 전체 훈련말뭉치에서 학습한 모델과 도메인 특화 모델 사이의 비율을 학습하기 위하여 사용하였다. 다음으로 번역성능을 확인하기 위하여 사용한 말뭉치는 1381개 문장을 사용하였다. 각 말뭉치의 자세한 정보는 표 1에 나타난 바와 같다.

4.2 분류 및 번역성능 비교

본 논문에서는 훈련말뭉치의 분류 방법으로 기본 분류 알고리즘과 개선된 분류 알고리즘의 두 가지 방법을 제안하고 있다. 이들의 성능확인을 위하여 훈련말뭉치를 4개의 클러스터로 분류하고, 그 결과에서 도메인 특화 번역을 실행하여 번역 성능을 비교하였다.

훈련말뭉치의 분류과정에서 기본 알고리즘을 사용한 경우는 훈련말뭉치 전체를 분류하였다. 개선된 알고리즘 사용시는 전체의 20%를 시드로 선택하여 분류 알고리즘에 따라 분류하고 나머지는 시드에서 계산한 값에 근거한 분류기를 사용하여 가장 적합한 클러스터에 배치하였다. 또한 두 알고리즘 모두 거리함수의 문장구조 유사도와 단어 유사도간 비율을 0:10에서 10:0까지 5가지 경우로 달리하여 실험하였다. 이 유사도간 비율을 탈리 설명하면 식 (6)에서 a 값을 각각 0, 0.3, 0.5, 0.7, 그리고 1로 적용한 거리함수를 분류 과정에서 사용한 것이다.

이렇게 유사도간 비율을 달리하는 것과 함께 훈련말뭉치를 클러스터로 분류하는 데 사용한 알고리즘 또한 기본 분류 알고리즘과 개선된 알고리즘의 두 가지를 모두 사용하여 실험하였다. 그 결과 분류된 훈련말뭉치의 세부도메인 각각에 특화된 번역시스템을 그림 3과 같이 구축하고 테스트말뭉치의 문장들을 분류기를 사용하여 해당하는 클러스터의 시스템에서 번역하였다.

상기한 바와 같이 클러스터별 번역 시스템을 구축하고 실제 번역을 수행하는 단계에서는 각 모델 사이에서 보간법의 적용비율을 별도의 말뭉치에서 학습한 실험결과와 학습을 거치지 않고 최적의 비율을 지정하여 번역한 경우의 두 가지 결과를 확인하였다.

다음에서는 각 과정에 따른 실험 결과를 표로 정리하였다. 두 유사도의 비율을 달리하며 기본 분류 알고리즘을 사용한 번역 결과를 보간법의 적용 대상과 보간법 적용 비율을 결정한 방법에 따라 학습을 통하여 보간법을 적용한 경우와 최적의 비율을 사용한 경우로 나누어 표 2에 정리하였다. 다음으로는 개선된 분류 알고리즘을 사용한 결과를 같은 방법으로 표 3에 나누어 정리하였다.

표 2와 표 3에 표시된 번역성능을 확인하면 보간법의 적용비율을 학습을 통해 획득한 값을 사용하였을 때는 큰 차이가 없으나 각 번역시스템이 최적의 성능을 발휘할 수 있도록 조정하였을 때의 번역성능에서는 일정한 향상이 있었음을 확인할 수 있다.

이렇게 최적의 성능을 발휘할 수 있도록 조정하였을 때의 보간법 적용 비율을 그림 3에 표시된 것과 같이 λ_{ci} 과 λ_{cti} 로 표현하면 각각은 언어모델과 번역모델에서 클러스터에 특화된 모델의 비율을 나타낸다. 이들은 최소 0에서 최대 0.9까지 다양한 분포를 보이며 실제 실험에서 어떤 클러스터의 경우는 클러스터 모델을 사용하지 않는 것이 가장 좋은 성능을 보였으나 일부 클러스터에

표 1 말뭉치 정보

말뭉치	크기		
	문장	단어	
		일본어	영어
Training	100,000	2,660,659	2,445,265
	Dev.	16,230	14,818
	Test	1,381	48,930

표 2 기본 알고리즘의 번역성능

비율	학습을 통한 보간법 적용		
	LM	TM	LM + TM
베이스라인			24.17
0:10	24.04	24.17	24.01
3:7	24.20	24.14	24.02
5:5	24.19	24.24	24.26
7:3	24.17	24.17	24.34
10:0	24.08	24.12	24.13
최적의 비율을 사용한 보간법 적용			
비율	LM	TM	LM + TM
0:10	24.25	24.46	24.54
3:7	24.36	24.23	24.60
5:5	24.44	24.46	24.62
7:3	24.44	24.44	24.67
10:0	24.46	24.39	24.58

표 3 개선된 알고리즘의 번역성능

비율	학습을 통한 보간법 적용		
	LM	TM	LM + TM
베이스라인	24.17		
0:10	24.11	24.15	24.17
3:7	24.23	24.23	24.23
5:5	24.23	24.23	24.26
7:3	24.23	24.23	24.32
10:0	24.19	24.15	24.19
비율	최적의 비율을 사용한 보간법 적용		
	LM	TM	LM + TM
0:10	24.34	24.39	24.60
3:7	24.38	24.50	24.76
5:5	24.35	24.55	24.62
7:3	24.48	24.45	24.63
10:0	24.34	24.28	24.47

서는 λ_{cl} 과 λ_{ct} 가 각각 0.7, 0.9의 값을 가질 때 최고의 번역성능을 보이는 등 보간법의 적용 비율은 분류된 말뭉치의 특성에 큰 영향을 받았다.

이 경우를 기준으로 하여 실험결과를 분석하면, 기본 알고리즘을 사용한 경우는 최대 약 0.5포인트, 개선된 알고리즘에서는 약 0.6포인트의 성능향상이 있었다. 베이스라인의 번역 결과와 비교할 때 상대적으로 2%, 2.5% 가량의 성능 개선으로, 각각 신뢰도 95%에서 유의성이 검증된 값이다.

이는 분류과정에 사용한 알고리즘에 따른 번역 성능의 차이가 크지 않으며 오히려 개선된 알고리즘을 사용하였을 때의 성능 향상이 더 우수할 수도 있다는 것을 보여준다. 따라서 알고리즘의 분류성능을 번역성능과 분류속도를 기준으로 판단하면 개선된 알고리즘이 더 뛰어남을 알 수 있다.

분류 알고리즘의 거리함수에서 문장구조 유사도와 단어 유사도의 비율을 달리한 결과를 확인하면 본 논문에서 제안한 방법을 기준연구들과 비교할 수 있다. 우선 말뭉치의 특성에서 기술한 바와 같이 문장유형만을 사용한 분류방법은 본 논문에서 사용한 말뭉치에는 적용하기가 곤란하므로 제외하고 장르에 따른 분류를 사용한 기준연구와 비교할 때, [6]의 실험결과는 단어 유사도를 기준으로 장르에 따른 분류를 수행하였으므로 문장구조 유사도의 적용 없이 단어 유사도만을 사용하여 말뭉치를 분류하고 실험한 결과들을 해당 기준연구와 동일하다고 고려할 때 두 유사도를 조합하여 말뭉치를 분류한 경우의 번역 성능이 더 뛰어나다. 즉 본 논문에서 제안하는 두 유사도를 동시에 사용하는 분류기법이 기준연구에 비하여 번역 성능 향상에 우수하다고 할 수 있다.

또한 보간법을 적용한 모델에 따른 변화를 관찰하면,

표 2의 번역 성능에서 언어모델만을 보간법의 대상으로 사용하였을 때의 번역 성능이 거리함수에서 문장구조 유사도의 비율이 높아질수록 향상되는 것을 볼 수 있다. 이것은 문장구조의 유사도가 언어모델의 성능 향상에 기여하는 것의 증거로 볼 수 있다. 거리함수에서 두 유사도의 비중을 5:5로 동일하게 사용하였을 때는 번역모델을 사용한 성능이 언어모델을 사용한 성능보다 우수하다. 이것은 말뭉치에서 문장유형의 변동이 거의 없기 때문이라 볼 수 있다. 그리고 모든 실험 결과에서 언어모델이나 번역모델 단독으로 보간법을 사용한 것 보다는 둘 다 사용한 성능이 우수하였다.

5. 결 론

본 논문에서는 문장구조와 단어의 유사도를 사용하여 말뭉치를 분류하고, 각 클러스터에 대하여 특화된 번역을 수행하는 방안을 제시하였다. 이는 말뭉치의 특성에 의존적이지 않은 비지도 기계학습으로 실험결과 그 성능향상을 확인하였다. 또한 문장유형의 구분을 말뭉치의 특성에 의존적이지 않게 수행할 수 있었던 점과, 번역할 문장과 가장 가까운 클러스터를 확인하는 도메인 예측에서 각각 기존의 연구에서 보였던 단점을 해결하였다. 그리고 분류과정에서 계산시간의 소요를 경감하기 위해서 개선된 분류 알고리즘을 제안하고 그 성능 또한 확인하였다.

향후 연구사항으로는 분류과정에서 유사도 계산법을 개선하여 쌍대비교를 회피하는 방안, 훈련말뭉치의 크기에 따른 차이의 확인, 다른 언어 쌍에 본 방법론을 적용하였을 때 결과의 확인 등이 있다. 번역과정에서 해결해야 할 사항으로는 보간법의 적용비율을 학습을 통하여 적용한 경우와 최적의 비율을 사용하였을 때의 차이를 줄이기 위하여 더 정교한 각 모델간 비율의 학습방안의 모색이 있겠다.

참 고 문 헌

- [1] S. Hasan, and H. Ney, "Clustered Language Models based on Regular Expressions for SMT," 10th EAMT conference "Practical applications of machine translation," pp.119-125, May. 2005.
- [2] H. Yamamoto, and E. Sumita, "Bilingual cluster based models for statistical machine translation," Proc. of the 2007 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning, pp.514-523, Jun. 2007.
- [3] A. Finch, and E. Sumita, "Dynamic Model Interpolation for Statistical Machine Translation," Proc. of the Third Workshop on Statistical Machine Translation, pp.208-215, Jun. 2008.

- [4] S. K. Choi, O. W. Kwon, K. Y. Lee, Y. H. Roh, S. K. Park, "Construction of English-Korean Automatic Translation System for Patent Documents Based on Domain Customizing Method," *Journal of KIISE : Software and Applications*, vol.34, no.2, pp.95-103, Feb. 2007. (in Korean)
- [5] K. Yasuda, A. Finch, and H. Okuma, "System Description of NiCT-ATR SMT for NTCIR-7," *Proc. of NTCIR-7 Workshop Meeting*, pp.415-419, Dec. 2008.
- [6] T. Ito, T. Akiba, and K. Itou, "Effect of the Topic Dependent Translation Models for Patent Translation - Experiment at NTCIR-7," *Proc. of NTCIR-7 Workshop Meeting*, pp.425-429, Dec. 2008.
- [7] G. Foster, and R. Kuhn, "Mixture-model adaptation for SMT," *Proc. of the Second Workshop on Statistical Machine Translation*, pp.128-135, Jun. 2007.
- [8] M. Collins, and N. Duffy, "Parsing with a Single Neuron: Convolution Kernels for Natural Language Problems," Technical report UCSC-CRL-01-01, 2001.
- [9] T. Kudo, and Y. Matsumoto, "Fast Methods for Kernel-based Text Analysis," *Proc. of the 41st Annual Meeting on Association For Computational Linguistics*, vol.1, pp.24-31, Jul. 2003.
- [10] A. Fujii, M. Utiyama, M. Yamamoto, and T. Utsuro, "Overview of the patent translation task at the NTCIR-7 Workshop," *Proc. of NTCIR-7 Workshop Meeting*, pp.389-400, Dec. 2008.
- [11] A. Stolcke, "Srilm - an extensible language modeling toolkit," *Proc. of the 7th International Conference on Spoken Language Processing (ICSLP)*, pp.693-696, Sep. 2002.
- [12] F. J. Och, and H. Ney, "A systematic comparison of various statistical alignment models," *Comput. Linguit.*, vol.29, no.1, pp.19-51, Mar. 2003.
- [13] P. Koehn, H. Hoang, A. Birch, C. C. Burch, M. Federico, N. Bertoldi, B. Cowan, W. Shen, C. Moran, R. Zens, C. Dyer, O. Bojar, A. Constantin, and E. Herbst, "Moses: Open Source Toolkit for Statistical Machine Translation," *Proc. of the 45th Annual Meeting of the Association for Computational Linguistics (ACL)*, Jun. 2007.
- [14] F. J. Och, "Minimum Error Rate Training for Statistical Machine Translation," *Proc. of the 41st Annual Meeting of the Association for Computational Linguistics (ACL)*, pp.160-167, 2003.
- [15] K. Papineni, S. Roukos, T. Ward, and W. Zhu, "BLEU: A method for automatic evaluation of Machine Translation," *Proc. of the 40th Annual Meeting on Association For Computational Linguistics*, Jul. 2001.



김 한 경

2008년 포항공과대학교 컴퓨터공학과 학사. 2010년 포항공과대학교 정보통신대학원 석사. 관심분야는 자연언어처리, 기계번역



나 휘 동

2007년 중앙대학교 컴퓨터공학과 학사 2007년~현재 포항공과대학교 컴퓨터공학과 석/박사 통합과정. 관심분야는 기계번역에 쓰이는 알고리즘 모델 연구



이 금희

1999년 중국 길림공업대학교 학사. 1999년~2001년 연변과학기술대학교 강사. 2003년 포항공과대학교 컴퓨터공학과 석사. 2003년~2005년 포항공과대학교 정보통신연구소 연구원. 2005년~현재 포항공과대학교 컴퓨터공학과 박사과정. 관심분야는 자연언어처리, 중한 기계번역, 중국어 분석 등



이 종혁

1980년 서울대학교 수학교육학과 학사 1982년 한국과학기술원 전산학과 석사 1988년 한국과학기술원 전산학과 박사 1989년~1991년 일본전기(NEC) 중앙연구소 초청연구원. 1991년~현재 포항공과대학교 컴퓨터공학과 교수. 1998년~1999년 미국 CRL/NMSU(뉴멕시코주립대학) 방문교수. 2007년~2008년 캐나다 RALI/University of Montreal 방문연구원. 관심분야는 자연언어처리, 기계번역, 정보검색 등