

문장 중요도를 이용한 자동 문서 범주화

(Automatic Text Categorization using the Importance of Sentences)

고영중[†] 박진우^{††} 서정연^{†††}

(Youngjoong Ko) (Jinwoo Park) (Jungyun Seo)

요약 자동 문서 범주화란 문서의 내용에 기반하여 미리 정의되어 있는 범주에 문서를 자동으로 분류하는 작업이다. 문서 분류를 위해서는 문서들을 가장 잘 표현할 수 있는 자질들을 정하고, 이러한 자질들을 통해 분류할 문서를 표현해야 한다. 기존의 연구들은 문장간의 구분 없이, 문서 전체에 나타난 각 자질의 빈도수를 이용하여 문서를 표현 한다. 그러나, 하나의 문서 내에서도 중요한 문장과 그렇지 못한 문장의 구분이 있으며, 이러한 문장 중요도의 차이는 각각의 문장에 나타나는 자질의 중요도에도 영향을 미친다.

본 논문에서는 문서 요약에서 사용되는 중요 문장 추출 기법을 문서 분류에 적용하여, 문서 내에 나타나는 각 문장들의 문장 중요도를 계산하고 문서의 내용을 잘 나타내는 문장들과 그렇지 못한 문장들을 구분하여 각 문장에서 출현하는 자질들의 가중치를 다르게 부여하여 문서를 표현한다. 이렇게 문장들의 중요도를 고려하여 문서를 표현한 기법의 성능을 평가하기 위해서 뉴스 그룹 데이터를 구축하고 실험하였으며 문장 중요도를 사용하지 않은 시스템 보다 향상된 성능을 얻을 수 있었다.

키워드 : 자동 문서 범주화, 문장 중요도, 문서 요약 기법

Abstract Automatic text categorization is a problem of assigning predefined categories to free text documents. In order to classify text documents, we have to extract good features from them. In previous researches, a text document is commonly represented by the frequency of each feature. But there is a difference between important and unimportant sentences in a text document. It has an effect on the importance of features in a text document.

In this paper, we measure the importance of sentences in a text document using text summarizing techniques. A text document is represented by features with different weights according to the importance of each sentence. To verify the new method, we constructed Korean news group data set and experiment our method using it. We found that our new method gave a significant improvement over a basis system for our data sets.

Key words : Automatic text categorization, Importance of sentence, Text summarization techniques

1. 서론

자동 문서 범주화(automatic text categorization)는 미리 정의된 범주(category)에 문서를 자동으로 할당하는 기법과 관련된 연구분야로서, 대량의 문서의 효율적인 관리 및 검색을 가능하게 하는 동시에 방대한 양의 수작업을 감소시키는 데 그 목적이 있다.

자동 문서 범주화 과정은 문서를 어떤 자질을 통해 표현할 것인가를 다루는 자질 추출(feature extraction) 과정과 추출된 자질로 표현된 문서를 어느 범주로 할당할 것인가를 결정하는 문서분류(text classification) 과정으로 구성된다.

자질 추출 과정에는 추출된 자질로 어떻게 문서를 표현할 것인가에 대한 색인(indexing) 과정이 포함되며, 가장 일반적인 색인 방법은 이른바 벡터 공간 모델(vector space model)이다. 이 모델은 문장의 구분 없이 전체 문서에 출현한 각 자질의 빈도수(TF)를 가지고 표현하는 방법이다. 그러나 문서 내에 나타나는 문장들 중에는 해당 문서의 핵심 내용을 잘 나타내는 문장과 그렇지 못한 문장들이 있으며, 이러한 문장 중요도의 차

[†] 비회원 : 서강대학교 컴퓨터학과
kyj@nlpzodiac.sogang.ac.kr

^{††} 비회원 : (주)다이퀘스트 선임연구원
jwpark@diquest.com

^{†††} 종신회원 : 서강대학교 컴퓨터학과 교수
kyj@nlpzodiac.sogang.ac.kr

논문접수 : 2001년 11월 15일
심사완료 : 2002년 5월 2일

이는 각 문장에 나타나는 자질의 중요도에도 영향을 미친다. 그러므로, 본 논문에서는 문서 요약 기법의 적용을 통해 중요한 문장과 그렇지 못한 문장을 구분하고, 각 자질이 어느 정도의 중요성을 지닌 문장으로부터 출현했는지를 색인 과정에 적용한다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 자동 문서 분류 시스템과 자동 문서 요약 분야에서 수행됐던 관련 연구들에 대해 살펴보고, 3장에서는 본 논문에서 제안하는 자동 문서 분류 시스템 모델에 대하여 자세히 설명한다. 그리고 4장에서 실험 및 평가를 하며, 5장에서는 결론 및 향후 연구를 기술한다.

2. 관련 연구

문서 분류 시스템은 미리 정의된 2개 이상의 범주에 문서의 내용을 파악하여 가장 관련이 있는 범주로 할당하는 시스템이다.

이는 문서 집합을 색인하고 분류하는 데 필요한 자질을 추출하는 자질 추출 과정과 추출된 자질을 기반으로 어떤 범주로 할당할 것인가를 결정하는 문서 분류 과정으로 나눌 수 있다. 후자의 문서 분류 방법에는 규칙 기반 모델(Rule-based Model), 확률적인 접근 방법의 단순 베이지언 확률 모델(Naive Bayesian probabilistic approach), 기계 학습(Machine Learning) 방법을 이용한 지지 벡터 기계(Support Vector Machine: SVM), 그리고 정보 검색 기법을 이용한 k-최근린법(k-Nearest Neigbor) 등이 있다[1,2]. 전자의 자질 추출 과정은 다시 자질 선택(feature selection) 단계와 색인(indexing) 단계로 나눌 수 있다.

자질 추출 과정 중 자질 선택 단계는 문서에 나타난 여러 단어들 중 범주화에 유용하게 사용될 만한 단어들을 선택하는 과정으로 문서 빈도(document frequency), 상호 정보 척도(mutual information), 카이 제곱 통계량 (χ^2 static), 정보 획득량(information gain) 등의 기법이 있다[3].

자질 추출 과정 중 색인 단계는 선택된 자질을 통해 문서를 표현하는 단계로서, 일반적으로 벡터 공간 모델이 사용된다[4]. 이것은 문서 전체에 나타난 자질들을 이용하여 문서를 하나의 벡터로 표현하는 것으로 보통 자질의 빈도수와 역 문헌 빈도수(IDF) 혹은 역 범주 빈도수(ICF)를 사용하여 문서를 표현한다[5]. 그러나 이러한 기존의 방법은 문서가 가진 자질의 위치 정보나 문장간 구분 등의 구조적 정보는 고려되지 못한다는 단점이 있다.

이러한 한계를 극복하기 위하여 다양한 연구가 있었는데, 먼저 문서의 구조적 정보를 살리기 위해 단어의

위치나 출현한 문장의 위치에 따라 가중치를 차등 적용한 방법이 연구되었으나, 모든 문서를 두괄식 또는 미괄식으로 가정하였기 때문에 신문 기사(article) 등 형식적인 문서를 제외하곤 그 적용이 힘들다[6]. 또한 제목이 있는 문서의 경우에 일반적으로 제목이 문서 전체의 내용을 대표하는 경우가 많으므로 제목에 가중치를 주는 방법이 있었지만, 제목이 문서를 대표할 만큼의 중요한 의미를 포함하고 있지 않다면 불필요하거나 오히려 모호성을 키우는 결과를 가져오기도 한다[7]. 이러한 현상은 뉴스그룹(newsgroup)이나 이메일(e-mail) 등 비 형식적인 문서에서 더 크게 부각된다.

하지만 중요한 것은 의미적으로 완전하지 못한 제목들도 문서를 작성한 의도와 목적을 포함하는 경우가 있다는 것이다. 따라서 제목에서 내포한 의도와 부합되면서 부가적인 설명을 하고 있는 문장이 본문에 존재한다면, 이 문장은 문서내의 다른 문장에 비해 더 중요하게 고려되어야 한다. 그러므로, 본 논문에서는 문서내의 전체 문장을 중에서 중요한 문장들을 찾아내기 위해 문서 요약 기법의 적용을 제안한다.

자동 문서 요약에 대한 기존 연구들은 방법론에 따라 크게 통계 정보에 기반한 방법과 언어학적 지식에 기반한 방법으로 나누어진다[8,9,10]. 본 논문에서는 자동 문서 분류를 하는 데 있어서 추가 부담을 줄이기 위해 적은 비용으로 빠르게 어느 정도 신뢰할 만한 결과를 얻을 수 있는 통계 정보를 이용한 방법을 사용하였으며, 이는 자동 문서 분류를 위한 학습 과정에서 얻어진 정보를 그대로 통계 정보로 활용할 수 있다는 장점이 있다.

본 논문에서는 여러 가지 문서 요약 기법 중에서 다음의 두 가지 문서 요약 기법을 적용하였다. 첫째는 제목과 문서의 모든 문장을 비교하여 문장간 유사도를 구하고 제목과 유사할수록 중요한 문장으로 결정하는 방법[8]이고, 둘째는 각각의 문장에 출현한 자질의 중요도에 따라 해당 문장의 중요도를 결정하는 방법[9]이다.

3. 문장 중요도를 반영한 자동 문서 범주화

3.1 전체 시스템 구조

전체 시스템은 크게 학습 과정과 문서 분류 과정으로 나뉜다. 학습 과정에서는 전처리 과정을 통해 학습 문서로부터 내용어를 추출하고, 자질 선택 과정에서는 카이 제곱 통계량을 이용하여 정보량에 따라 내용어를 순위화한다. 결정된 내용어의 순위는 색인 과정에서 자질의 수를 제안하는 데 사용된다.

문서 분류 과정에서 입력 문서는 전처리 과정을 통해 문장 단위로 내용어가 추출되며, 문장 단위로 추출된 내

용어를 통해 문서내의 모든 문장들을 문장 벡터로 표현 한다. 문장 중요도 계산 과정에서는 두 가지 방법으로 문장 중요도를 계산한다. 첫째는 제목과의 유사도를 구하여 높은 유사도를 가질수록 높은 중요도를 주는 방법이고, 둘째는 문장에 중요한 자질이 많이 나오면 높은 중요도를 주는 방법이다. 여기서, 문장에 출현한 자질의 중요도를 계산하기 위하여 학습 과정에서 계산된 자질의 정보량과 문헌 빈도수를 사용한다. 결국 문장의 중요도는 이 두 가지 방법으로 얻어진 문장 중요도를 통합함으로써 얻어지고 이렇게 얻어진 문장 중요도는 색인 과정에 적용된다. 색인 과정에서는 전처리 과정에서 만 들어진 문장 벡터들을 모두 합함으로써 하나의 문서 벡터를 만드는데, 이때 문장 벡터에 해당 문장의 문장 중요도가 꽂해진다. 따라서 문서 벡터에 나타나는 각 자질의 빈도수는 문장 중요도에 따라 실제 나타난 빈도수보다 더 높은 값을 가지게 된다. 이렇게 표현된 문서 벡터는 문서 분류기를 통해 범주를 할당받게 된다.

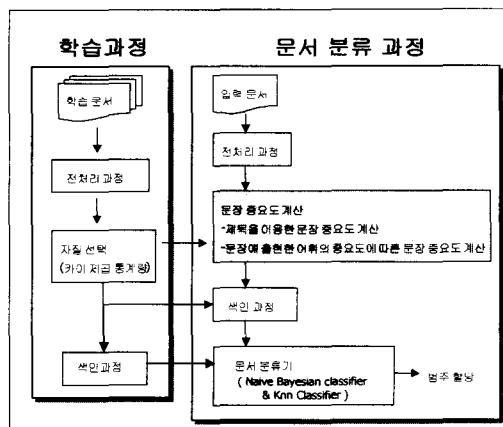


그림 1 제안한 시스템의 전체 구성도

3.2 전처리 과정

뉴스그룹의 문서는 총 7개의 필드(제목, 저자, 날짜, 그룹, 서버, IID, 본문)로 이루어져 있으며, 제안된 시스템에서는 제목과 본문만을 이용했다. 문장의 내용이나 특징을 잘 반영하는 단어를 내용어(content word)라고 하는데 본 시스템에서는 내용어로서 형태소 분석의 결과 중 명사만을 고려하였다. 본 논문에서 사용한 한국어 형태소 분석기는 diAna-M (DiQuest Analyzer Morpheme)¹⁾이다.

1) dianaM은 (주)다이퀘스트닷컴(www.diquest.com)에서 개발한 형태소 분석기이다.

전처리 과정을 통해 입력 문서는 문장 단위로 내용어를 추출하게 되고, 추출된 내용어를 사용하여 문장 벡터들을 구성한다.

3.3 자질 선택

Yiming Yang은 [3]에서 여러 가지의 자질 추출 방법을 사용하여 실험을 한 결과 카이제곱 통계량과 정보 획득량을 사용하는 것이 가장 효과적임을 보였다. 본 논문에서는 이를 바탕으로 비교적 구현이 쉽고 고빈도 단어에 친화적인 카이 제곱 통계량을 사용하여 자질을 선택한다. 카이 제곱 통계량을 구하기 위한 식은 다음과 같다.

$$\chi^2(t, c) = \frac{N \times (AD - CB)^2}{(A + C) \times (B + D) \times (A + B) \times (C + D)} \quad (1)$$

여기에서 A는 범주 c에 속해 있는 문서 중 용어 t를 포함하고 있는 문서의 수, B는 범주 c에 속하지 않은 문서 중 용어 t를 포함하고 있는 문서의 수, C는 범주 c에 속해 있는 문서 중 용어 t를 포함하지 않은 문서의 수, 그리고 D는 범주 c에 속하지 않은 문서 중 용어 t를 포함하지 않은 문서의 수이다.

각 범주 별로 얻어진 카이 제곱 통계량 값은 다음과 같은 식에 의해 가장 큰 값이 해당 용어의 자질 값이 되며 이 값을 순위화하여 자질 값이 높은 순으로 선택한다.

$$\chi^2 \max(t) = \max_{i=1}^n \{\chi^2(t, c_i)\} \quad (2)$$

또한 여기서 구해진 자질 값은 문장의 중요도를 구하기 위해 다시 사용된다.

3.4 문장 중요도 계산

문장 중요도는 두 가지 방법에 의해서 구해진다. 하나는 제목과의 유사도를 구하여 유사도가 높을수록 높은 중요도를 주는 방법이고, 다른 하나는 문장에 출현한 단어들의 정보량을 판단하여 정보량이 많은 단어들이 나온 문장에 높은 중요도를 주는 방법이다. 결국 문장 중요도는 이 두 가지 방법에 의해 구해진 문장 중요도를 합하여 결정된다.

3.4.1 제목을 이용한 문장 중요도 계산

일반적으로 제목은 본문에 비해 문서 전체에서 중요한 의미 또는 의도를 갖는 경우가 많다. 따라서 제목에 가중치를 부여하는 방법이 이전에 시도되었으나 제목이 문서 전체의 의미를 대표하지 못하는 경우 오류를 일으키거나 그 적용에 한계가 있었다. 이러한 문제점은 뉴스 그룹 문서나 이메일 등의 비형식적인 문서에서 더욱 심하게 나타난다. 다음은 뉴스 그룹 문서들의 제목과 본문의 일부만을 모은 예제이다.

1) 제목: 노래 제목과 가수 이름을 알고 싶어요.
2) 제목: 질문이 있는데요...
본문: 제가 음악에 대해 잘 몰라서 질문 좀...
3) 제목: 자료를 구하고 싶은데...
본문: 게임 관련 자료를 얻으려면...
4) 제목: 공연 정보
본문: 디아는 우리 음악과 차의 향기가 어우러지는 공연으로 공연내용은 연주자 사정상 바뀔 수 있습니다.

첫번째 예제 1)의 제목은 제목만을 보고서도 음악과 관련된 문서라는 사실을 알 수 있으며, 글을 올린 목적을 명확히 파악할 수 있다. 그러나 다음에 나오는 2), 3), 4)의 제목은 무슨 질문이 있는 건지, 무슨 자료를 원하는 것인지, 무슨 공연에 대한 정보인지를 명확히 알 수 없으며, 따라서 이러한 제목들은 제목 자체만으로는 문서를 분류하는 데 별 도움을 주지 못한다. 하지만 중요한 것은 이렇게 모호한 제목들조차도 문서 전체의 의도를 포함하고 있다는 것이다. 따라서 제목에서 내포한 의도와 부합되면서 부가적인 설명을 하고 있는 문장이 본문에 존재한다면 이 문장은 문서내의 다른 문장에 비해 더 중요하게 고려되어야 할 것이다. 예제 2)를 보면 "질문"이라는 단어를 공유한 본문의 문장에서 질문 내용이 음악에 관련한 것이라는 사실을 말하고 있으며, 예제 3)에서는 "자료"라는 단어를 공유한 본문의 문장에서 원하는 자료가 게임과 관련된 자료라는 것을 의미하고 있다. 마지막으로 예제 4)에서 제목에 나오는 "공연"이라는 단어는 본문에서 지속적으로 출현하면서 공연에 대하여 자세히 설명하는 문장을 이끌고 있다. 따라서 제목과 유사한 문장에 출현하는 단어들은 해당 문서의 의도를 자세히 나타내고 있는 경우가 많으며, 이러한 단어들은 문서를 분류하는 데 중요한 기준이 된다.

본 논문에서는 제목의 의미 또는 의도를 포함하고 있는 문장을 중요한 문장으로 인정하고, 이를 판단하기 위해 제목과 문서내의 모든 문장들과 유사도를 구하여 제목과 유사할수록 높은 중요도를 부여한다.

제목과 문서의 각각의 문장들과 유사도를 구하기 위해 각 문장은 내용어의 벡터로 표현되고, 다음과 같이 내적을 통해 그 유사도를 계산한다. 이렇게 구한 제목과 각 문장의 유사도는 해당 문서에서 가장 높은 문장 유사도 값으로 나누어 줌으로써 0에서 1사이로 정규화 한다.

$$\text{Sim}(S_i, T) = \frac{\vec{S}_i \cdot \vec{T}}{\max_{S_j \in D} (\vec{S}_j \cdot \vec{T})} \quad (3)$$

위의 식에서 D는 문서이고, T는 문서 D의 제목, S는

문서 D의 문장이다. $\text{Sim}(S_i, T)$ 는 제목 T와 i 번째 문장 S_i 의 유사도이며, \vec{T} 는 내용어로 이루어진 제목의 문장 벡터이고, \vec{S}_i 는 문장 S_i 의 문장 벡터이다.

3.4.2 출현 자질에 따른 문장 중요도 계산

만약 제목이 아무런 의미도 갖지 못함은 물론 문서의 의도 조차도 내포하지 못한다면 3.4.1 에서 사용한 방법은 불필요하거나 문서를 왜곡시킬 수 있을 것이다. 제목과 유사한 문장이라도 중요한 의미를 담고 있는 자질을 포함하고 있지 않다면 중요한 문장이 될 수 없으며, 반대로 제목과 유사성이 없는 문장이라도 중요한 의미를 포함한 자질들이 나타나는 문장이라면 중요하게 고려해야 한다.

자동 문서 요약 기법 중에는 문장에 출현하는 각 자질들의 중요도(Centroid)를 측정하고 이를 합하여 문장의 중요도를 결정하는 방법이 있다[9]. 이 방법을 통해서 제목이 없는 경우나 제목이 있어도 전혀 무의미한 것일 때에도 문장의 중요도를 구할 수 있다.

표 1 학습 과정에서 얻어진 자질들의 정보

순위	자질	χ^2	문헌빈도수(df)
1	영화	3729.6	211
2	리눅스	2795.3	746
3	하나님	2438.6	58
4	여행	2418.1	72
5	노래	2382.0	168
44	언론	1256.4	326
46	디아	1235.1	46
61	조선	1071.0	273
70	정부	930.0	265
426	보드	319.2	115
683	베틀넷	241.1	11
1896	감독	135.6	30
3296	동아	94.1	31
3766	그래픽카드	82.1	29
3978	중앙	78.1	43
5493	영화제	69.5	2

위의 [표 1]은 학습과정에서 얻어진 자질 정보의 예(상위 5개와 뒤에서 언급될 자질들)이며, 이러한 정보를 이용하여 각 문장의 중요도를 구하기 위하여 각 자질의 빈도수($f(t)$)와 역문헌 빈도수($idf(t)$), 그리고 카이 제곱 통계량(χ^2)을 이용하여 각 자질의 중요도를 구하고 다음 식(4)와 같이 문장의 중요도를 계산한다.

$$\text{Cen}(S_i) = \frac{\sum_{t \in S_i} f(t) \times idf(t) \times \chi^2(t)}{\max_{S_j \in D} \left\{ \sum_{t \in S_j} f(t) \times idf(t) \times \chi^2(t) \right\}} \quad (4)$$

여기서 $Cen(S_i)$ 는 문장 S_i 의 문장 중요도이다.

위의 식을 통해 더 적은 문서에 나타날수록, 카이 제곱 통계량에 의해 얻어진 정보량 값이 클수록 중요한 자질이고, 이러한 중요한 자질이 많이 나타난 문장일수록 문장 중요도가 크게 나타난다.

3.4.3 문장 중요도의 통합

두 가지 방법의 문장 유사도 계산이 끝나면 식(3)의 제목과의 문장 유사도와, 식(4)에서의 출현 자질들의 중요도에 따른 문장 중요도는 다음과 같은 식에 의해 통합된다.

$$Score(S_i) = 1.0 + k_1 \times \text{Sim}(S_i, T) + k_2 \times Cen(S_i) \quad (5)$$

위의 식에서 k_1 과 k_2 는 두 가지 방법의 적용 정도와 비율을 조정하기 위한 실험값이며, 이 식을 통해 각 문장은 하나의 문장 중요도 값을 가지게 된다. 제목과의 문장 유사도를 구하기 위해서는 무엇보다도 제목이 있어야 하므로, 두 가지 방법을 이용하여 문장 중요도를 구하는 것은 본 논문에서의 실험 대상인 뉴스 그룹 문서와 같이 제목이 있는 경우에만 가능하다. 만약 제목이 없는 문서라면 자질 중요도를 이용하는 식 (4)의 방법만을 이용하여 문장 중요도를 판단해야 할 것이다.

3.5 색인 과정

문장 중요도 계산 과정에서 얻어진 문장 중요도는 문서를 하나의 벡터로 표현할 때 자질의 빈도수에 가중치를 주기 위해 사용된다. 즉, 문서에 출현한 자질의 빈도수는 각 문장에 출현한 자질의 빈도수의 합으로 구해지는데 이때 출현한 문장의 중요도에 따라 더해지는 빈도수가 달라지게 된다. 이를 나타내는 식은 다음과 같다.

$$N(t|d) = \sum_{S_i \in d} tf(S_i, t) \times Score(S_i) \quad (6)$$

위 식에서 $tf(S_i, t)$ 는 문장 S_i 에서 출현한 자질 t 의 빈도수이며, $N(t|d)$ 는 문장 중요도에 의해 가중치가 적용된 문서 d 에 출현한 자질 t 의 빈도수이다.

위 식에 따르면 각 자질은 출현한 문장의 중요도(Score) 만큼의 가중치를 받게 되므로, 중요한 문장에 나온 자질은 실제로 출현한 빈도수보다 높은 값을 가지게 된다.

3.6 문서 분류기

본 논문에서 사용한 문서 분류기는 단순 베이지안 확률 모델과 k-최근린법이다. 단순 베이지언 확률 모델은 대상 문서가 각 범주에 속할 확률을 구해 가장 큰 확률 값을 갖는 범주에 그 문서를 할당하는 기법이다. 이는 다음과 같은 식으로 나타난다.

$$\begin{aligned} \underset{c}{\operatorname{argmax}} [\Pr(c|d)] &= \underset{c}{\operatorname{argmax}} \left[\frac{\Pr(c)\Pr(d|c)}{\Pr(d)} \right] \\ &= \underset{c}{\operatorname{argmax}} \left[\Pr(c) \prod_{i=1}^T \Pr(t_i|c)^{N(t_i|d)} \right] \end{aligned} \quad (7)$$

여기서 $N(t_i|d)$ 는 문서 d 에서의 자질 t_i 가 출현하는 빈도수를 의미하고 T 는 전체 문서 집합내의 자질의 수를 나타낸다. 일반적으로 문서 d 에 자질 t_i 의 빈도수가 높고 범주 c 에 자질 t_i 가 많이 나타나면 문서 d 가 범주 c 에 속할 확률은 높아진다. 그러나 위의 식에서는 자질 t_i 가 문서 d 에서 출현 빈도수가 높을수록 $\Pr(t_i|c)$ 값을 출현 빈도수 만큼 곱함으로써 오히려 $\Pr(c|d)$ 의 확률값이 작아진다. 이러한 문제를 해결하기 위하여 Kulback-Leiber Divergence를 사용하여 다음과 같이 변환한다 [11]. Kulback-Leiber Divergence는 두 확률 분포가 얼마나 유사한지를 측정하는 척도로 사용되는 식이다[12]. 이 식을 단순 베이지안 식에 적용함으로써 확률값을 곱하여 계산하는 것을 덧셈으로 치환할 수 있기 때문에 $\Pr(c|d)$ 값이 빈도수에 비례해서 작아지지 않도록 할 수 있다.

$$\Pr(c) \prod_{i=1}^T \Pr(t_i|c)^{N(t_i|d)} \propto \frac{\log \Pr(c)}{n} + \sum_{i=1}^T \Pr(t_i|d) \log \left(\frac{\Pr(t_i|c)}{\Pr(t_i|d)} \right) \quad (8)$$

여기서 n 은 문서 d 에 출현하는 모든 자질의 빈도수의 합이고, $\Pr(c)$ 는 전체 학습 문서 집합에서의 해당 범주가 나타날 확률을 의미하며, $\Pr(t_i|c)$ 는 해당 범주에서 자질 t_i 가 나타날 확률을, 그리고 $\Pr(t_i|d)$ 는 대상 문서에서 자질 t_i 가 나타날 확률을 의미한다. 각각의 확률식은 다음과 같다[13].

$$\Pr(t_i|c) = \begin{cases} \frac{N(t_i|c) + 0.5}{\sum_i^T N(t_i|c) + 0.5 \times T_c} & \text{if } N(t_i|c) \neq 0 \\ \frac{N(t_i|d) + 0.5}{\sum_i^T N(t_i|d) + 0.5 \times T_d} & \text{if } N(t_i|d) \neq 0 \\ 0 & \text{if } N(t_i|d) = 0 \end{cases} \quad (9)$$

여기서 $N(t_i|c)$ 는 범주 c 에서의 자질 t_i 가 출현한 빈도이며 T_c 는 범주 c 의 자질의 총수이다. 그리고 $N(t_i|d)$ 는 3.5의 식(6)에서 구한 문서 d 에서 출현한 자질 t_i 의 빈도수이다.

최근린법은 새로운 문서가 들어왔을 때 학습 문서 중에서 가장 유사한 문서의 범주로 새로운 문서를 할당하는 방법이며, 이를 일반화하여 입력 문서를 학습 문서와 비교하여 가장 유사한 k개의 학습 문서를 보고 입력 문서의 범주를 결정하는 것이 k-최근린 법이다. 본 논문에서는 문서의 각 자질을 TF-IDF 가중치를 사용하여 문서 벡터로 표현하고, 문서간의 유사도를 측정하기 위하여 코사인 유사도(cosine similarity) 방법을 사용하였다. 최종적으로 입력 문서의 범주를 결정하기 위해서는 다음 식 (10)과 같이 각 범주별로 유사도를 합하여 가

장 큰 유사도를 가지는 범주로 할당하는 방법을 사용하였다[1,2].

$$s(c_i, d) = \sum_{d' \in R_k(d) \cap D_i} \cos(d', d) \quad (10)$$

여기서, 집합 $R_k(d)$ 는 입력 문서와 가장 유사한 k개의 학습 문서 집합이며, D_i 는 범주 c_i 의 학습 문서 집합이다.

4. 실험 및 평가

4.1 성능 평가 방법

본 논문에서는 기본 시스템과의 비교를 통해 제안된 기법과의 성능을 평가하였는데 여기서 제안된 기법을 사용한 시스템은 식(6)을 통해 각 자질의 빈도수를 변형해서 사용한 시스템이며 기본 시스템은 자질 빈도수를 변형하지 않은 원래의 자질 빈도수를 그대로 사용한 시스템이다.

본 논문에서 하나의 문서는 단지 하나의 범주로만 할당된다. 본 시스템의 평가 방법으로는 정보 검색 분야에서 일반적으로 사용되는 정확율(precision), 재현율(recall), 그리고 F_1 -measure를 사용하였고, 모든 범주의 성능을 통합하여 평가하기 위한 기법으로는 micro-averaging 기법을 사용하였다.

4.2 실험 데이터

실험에 사용된 데이터는 서강대학교 뉴스 서버로부터 수집한 문서이다. 총 10,331개의 문서로 구성되어 있으며, 학습 문서로 7,224개를, 실험 문서로 3,107개를 사용하였다. [표 2]와 같이 15개의 범주를 사용하였고 각 범주에 속해 있는 문서의 수는 각각 다르다. 각 문서는 하나의 범주만을 가지며 중복 할당을 허용하지 않았다.

표 2 실험 데이터의 구성

범주	학습문서	실험문서	총계
han.arts.music	315	136	451
han.comp.databas	198	86	284
han.comp.devtools	404	174	578
han.comp.lang	1387	595	1982
han.comp.os.linux	1175	504	1679
han.comp.os.windows	517	222	739
han.comp.sys	304	131	435
han.politics	1469	630	2099
han.rec.cars	291	126	417
han.games	261	112	373
han.movie	202	88	290
han.sports	130	56	186
han.travel	102	45	147
han.sci	333	143	476
han.soc.religion	136	59	195
총계	7224	3107	10331

4.3 실험 결과

첫번째 실험은 학습 과정에서 얻어진 총 69,793개의 내용어 중 자질 선택 과정을 통해 1,000개에서 20,000개 까지 자질의 수를 제한하여 기존의 시스템과 제안한 시스템의 성능을 단순 베이지언 모델과 k-최근린법을 사용한 분류기를 사용하여 각각 비교하였다. 이때 식(5)에서 정의한 상수 k_1 과 k_2 는 1.0으로 정하였으며 실험 결과는 다음과 같다.

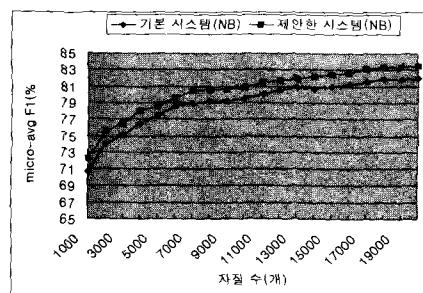


그림 2 단순 베이지언 분류기를 사용한 자질 수에 따른 성능 비교 그래프

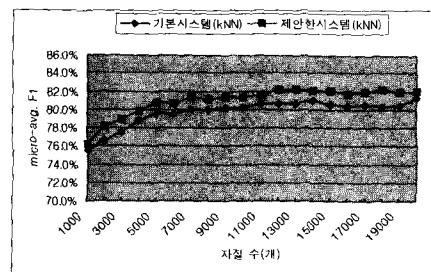


그림 3 k-최근린법 분류기를 사용한 자질 수에 따른 성능 비교 그래프

위의 첫 번째 실험 결과에서는 자질의 수를 증가시킴에 따라, 두 개의 문서 분류기를 사용한 실험에서 모두 급격한 성능의 향상을 보이다가 자질 7,000개 이상에서는 거의 수렴하면서 완만한 상승을 보이고 있다. 이러한 현상은 기본 시스템과 제안한 시스템에서 비슷하게 나타나며, 자질의 수에 상관없이 제안한 시스템이 기본 시스템에 비해 단순 베이지언 모델을 사용한 분류기에서는 평균 1.4%의 성능 향상을, 그리고 k-최근린법을 사용한 분류기에서는 평균 1.3%의 성능 향상이 있음을 볼 수 있다.

다음 실험은 문장 중요도를 구하기 위해 사용한 두 가지 방법이 각각 성능 향상에 어떻게 영향을 미치는지

알아보기 위한 실험이다. 이 실험은 단순 베이지언 모델을 사용하였으며, 자질 수의 증가에 따른 성능향상이 1차적으로 수렴되고 있는 7,000개의 자질을 사용했을 때를 기준으로 실험하여 실험 상수 k_1 과 k_2 를 0에서 5까지 변화시키면서 비교 실험하였다.

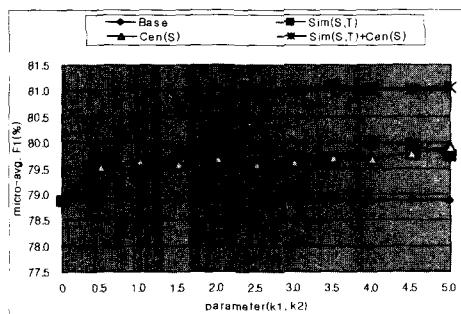


그림 4 실험 상수 변화에 따른 성능 비교

위 [그림 4]의 그래프를 보면 제목과의 유사도를 통해 문장 중요도를 구하는 방법($Sim(S,T)$)과 문장에 출현한 자질의 중요도를 합하여 문장 중요도를 구하는 방법($Cen(S)$)을 모두 적용한 경우가 가장 성능이 우수했으며, 두 가지 방법 중 하나만을 사용한 경우도 기본 시스템에 비해 좋은 성능을 보이고 있다. 특이한 것은 두 가지 방법 중 하나만을 사용한 경우는 k_1 과 k_2 를 각각 증가시켰을 때 1.0 이상에서 약간의 불규칙적인 상승과 하락을 보이면서 불안정한 수렴을 하는 반면, 두 가지 방법을 같이 적용한 경우에는 2.5까지 꾸준한 성능 향상을 보이다가 안정적인 수렴을 하는 양상을 보인다. 이 실험의 결과를 통해 제안한 두 가지 문장 중요도 계산 방법 중 어느 방법을 사용해도 성능의 향상을 기대할 수 있으며, 두 가지 방법을 모두 사용하면 서로 보완을 통해 상승 효과(synergy)를 일으키며 추가적인 성능 향상이 일어난다는 것을 알 수 있다.

4.4 결과 분석

이번 절에서는 제안한 방법의 타당성을 확인하기 위하여 예제를 통해 실험결과를 분석하여 보았다.

위의 예제는 실험문서 중 게임(han.rec.games)의 범주에 해당 하는 문서이다. 위의 문서는 한눈에 “디아”와 “배틀넷”이라는 단어를 보고 게임과 관련된 문서라는 사실을 알 수 있지만 실제로 기준 시스템은 “그래픽카드”, “보드” 등 시스템 관련 단어들이 더 많이 나오므로 오히려 시스템(han.comp.sys)의 범주로 오인하는 결과를 보였다. 그러나 제안한 시스템에서는 문장 중요도 계산을 통해 “다운”이라는 단어를 제목과 공유하고, 중요도가 높은 단어인 “배틀넷”이라는 단어를 포함한 문장 1)이 가장 중요한 문장으로 인식되며, 따라서 “배틀넷”에 가중치가 월등하게 많이 적용되어 올바르게 게임 범주로 분류하는 결과를 볼 수 있다.

제목: 라쇼몽을 기억하며.

본문: 1) 1951년 베니스 영화제 그랑프리를 수상하며 아시아 영화의 위상을 세계에 알린 구로사와 아키라 감독의 작품 라쇼몽을 기억하십니까?
2) 진실을 보고 싶어도 볼수가 없지요.
3) 저는 다만 그 조선.중앙.동아 삼총사에 정부와 기타 잡다 언론들 상당수를 같이 쓸어 넣어야 한다는 생각입니다.

위 예제는 정치(han.politics)의 범주에 속하는 문서이지만, “라쇼몽”이라는 영화에 빗대어 정치적 소견을 이야기하고 있다. 실제로 제목과의 유사도만을 이용하여 문장 중요도를 구한 경우 “라쇼몽”과 “기억”이라는 내용어를 포함한 문장 1)이 가장 중요한 문장이 되고, 이 문장은 영화관련 자질을 많이 포함하고 있으므로 이 문서는 영화(han.rec.movie) 범주로 결정된다. 그러나 [표 1]과 같은 자질들의 정보를 반영한, 자질 중요도를 이용하여 문장 중요도를 구하는 방법을 적용하면 “영화제”, “영화”, “감독” 등의 자질이 출현한 문장 1)보다 “조선”, “중앙”, “동아”, “정부”, “언론” 등의 자질을 포함한 문장 3)의 중요도를 더 높여주게 된다. 따라서 이 예제를 통해 자질 중요도를 이용하는 방법이 제목과의 유사도를 이용한 방법에서 발생하는 오류를 보정해 주는 것을 확인할 수 있었다.

5. 결론 및 향후 과제

본 논문에서는 문서 요약 기법을 적용한 자동 문서 분류 시스템을 제안하였다. 제목을 이용하여 제목과의 문장 유사도를 통해 문장 중요도를 측정하는 방법과 문장에 출현한 자질들의 중요도를 더하여 문장 중요도를 구하는 방법을 이용하여 문서 전체의 문장 중요도를 구하였다. 이렇게 구해진 문장 중요도를 색인 과정에서 각

제목: 디아하다가 다운이 되요.
본문: 1) 2를 구해서 하고 있는데 배틀넷 들어갔다가 나오면서 자꾸 다운이 되네요.
2) 우리집 그래픽 카드가 세비지 4인데
3) 이것 매문인지도 의심이가고 제이스택에서 나온 건데
4) 보드는 유니텍 BX 보드이고요.
5) 아시는 분 도와주세요.

자질의 빈도에 차등 적용하였다. 제안된 방법은 뉴스 그룹 데이터에서 단순 베이지언 모델과 k-최근접법을 사용한 분류기를 사용하여 실험되었으며, 단순히 문서 전체에 출현한 단어의 빈도수를 이용하여 문서를 표현했을 때보다 두 개의 분류기에서 모두 약 2% 정도의 성능 향상을 얻을 수 있었다.

향후 과제로는 본 논문에서는 뉴스 그룹 데이터에서 실험하였으나, 뉴스 그룹 데이터 외에 기사(article), 웹 문서 등 다양한 영역에 적용하는 연구가 필요할 것이다.

참 고 문 헌

- [1] Yang, Y. and Xin Liu. "A re-examination of text categorization methods." In Proc. of Conference on Research and Development in Information Retrieval (SIGIR 99), pp.42~49, 1999.
- [2] Yang, Y. "An evaluation of statistical approaches to text categorization." Journal of Information Retrieval, Vol 1, No. 1/2, pp 67~88, 1999.
- [3] Yang, Y., Pedersen, J.O., "A Comparative Study on Feature Selection in Text Categorization," In Proc. of The 14th International Conference on Machine Learning (ICML' 97) , pp.412~420, 1997.
- [4] Salton G., Fox E. A. and Wu H., "Extended boolean information retrieval." Communications of the ACM, Vol. 26, No. 12, pp.1022~1036, 1983.
- [5] Ko Y. and Seo J., "Automatic Text Categorization by Unsupervised Learning," In Proc. of the 18th International Conference on Computational Linguistics, (COLING 2000), pp.453~459, 2000.
- [6] Murata M., Ma Q., Uchimoto K., Ozaku H., Isahara H., and Utayama M., "Information retrieval using location and category information." Journal of the Association for Natural Language Processing, Vol. 7, No. 2, 2000.
- [7] Mock, K. J. "Hybrid hill-climbing and knowledge-based techniques for intelligent news filtering." In Proc. of The National Conference on Artificial Intelligence (AAAI'96), 1996.
- [8] Goldstein J., Kantrowitz M., Mittal V. O., and Carbonell J., "Summarizing Text Documents: Sentence Selection and Evaluation Metrics." In Proc. of SIGIR' 99, 1999.
- [9] Radev, D. R, Jing, H., and Stys-Budzikowska, M., "summarization of multiple documents: clustering, sentence extraction, and evaluation." Proceedings, ANLP-NAACL Workshop on Automatic Summarization, April, 2000.
- [10] Marcu D., "Discourse trees are good indicators of importance in text." *Advances in Automatic Text Summarization*. pp.123~136 The MIT Press, 1999.
- [11] Craven, M., DiPasquo, D., Freitag, D., McCallum, A., Mitchell, T., Nigam, K., & Slattery, S., "Learning to Construct Knowledge Bases from the World Wide Web." In Proc. of the Fifteenth National Conference on Artificial Intelligence (AAAI-98), pp. 509~516. 1998.
- [12] Manning C. D. and Schütze H., *Foundations of Statistical Natural Language Processing*, The MIT Press, 1999, Second Edition.
- [13] Li H. and Yamanishi K., "Document Classification Using a Finite Mixture Model." The Association for Computational Linguistics(ACL' 97), 1997.

고영종



체명 인식 등

1996년 서강대학교 수학과 학사. 1996년 ~ 1997년 LG-EDS systems 근무. 2000년 서강대학교 컴퓨터학과 석사. 2000년 ~ 현재 서강대학교 컴퓨터학과 박사과정. 관심분야는 한국어 정보 처리, 자연어 처리, 문서 범주화, 문서 요약, 개인화 서비스 등

박진우



1997년 서강대학교 컴퓨터학과 학사. 2002년 서강대학교 컴퓨터학과 석사. 2002년 ~ 현재 (주)다이퀘스트 선임연구원. 관심 분야는 자연어 처리, 한국어 정보 처리, 정보검색 등

서정연



1981년 서강대학교 수학과 학사. 1985년 미국 Univ. of Texas, Austin 전산학과 석사. 1990년 미국 Univ. of Texas, Austin 전산학과 박사. 1990년 ~ 1991년 미국 Texas Austin, UniSQL Inc. Senior Researcher. 1991년 한국과학기술원 인공지능 연구 센터 선임연구원. 1991년 ~ 1995년 한국과학기술원 전산학과 조교수. 1996년 ~ 현재 서강대학교 정교수. 관심 분야는 한국어 정보 처리, 자연어처리, 대화처리, 지능형 정보 검색 등