

다중 가중치 기법을 이용한 검색 효과의 개선

Improving Retrieval Effectiveness with Multiple Weighting Schemes

이준호(Joon-Ho Lee)*

□ 목 차 □

- | | |
|--|--|
| 1. 서 론
2. SMART 시스템
2.1 유사도 계산
2.2 가중치 부여 기법
3. 가중치 기법들에 대한 분석 | 3.1 문서 형태 분류
3.2 가중치 기법의 특성
4. 성능 평가
5. 결 론 |
|--|--|

초 록

질의 또는 문서에 대한 상이한 표현 방법 또는 상이한 검색 기법은 서로 다른 집합의 문서들을 검색함이 알려져 왔다. 최근 이러한 특성을 이용하여 다양한 표현 방법 또는 검색 기법을 결합함으로써 보다 높은 검색 효과를 얻을 수 있음이 입증되었다. 본 논문에서는 질의와 문서에 대한 하나의 표현과 하나의 검색 기법하에서 서로 다른 특성을 갖는 가중치 기법을 결합함으로써 보다 높은 검색 효과를 얻을 수 있음을 기술한다. 문서의 형태를 분류하고 가중치 기법의 특성을 기술한 후, 이를 기반으로 하여 서로 다른 특성을 갖는 가중치 기법은 서로 다른 형태의 문서를 검색함을 설명한다. 또한 실험을 통하여 서로 다른 특성을 갖는 가중치 기법을 결합함으로써 보다 높은 검색 효과를 얻을 수 있음을 입증한다.

ABSTRACT

It has been known that different representations of either queries or documents, or different retrieval techniques retrieve different sets of documents. Recent works suggest that significant improvements in retrieval performance can be achieved by combining multiple representations or multiple retrieval techniques. In this paper we propose a simple method for retrieving different documents within a single query representation, a single document representation and a single retrieval technique. We classify the types of documents, and describe the properties of weighting schemes. Then, we explain that different properties of weighting schemes may retrieve different types of documents. Experimental results show that significant improvements can be obtained by combining the retrieval results from different properties of weighting schemes.

* 연구개발정보센터 연구개발부 선임연구원

■ 논문접수일 : 1995년 11월 1일

1. 서 론

정보 검색 시스템의 중요한 역할 중의 하나는 문서가 질의를 만족하는 정도를 나타내는 문서값(document value)을 보다 정확히 계산함으로써, 높은 검색 효과(retrieval effectiveness)-높은 재현율(recall)과 정확률(precision)을 제공하는 것이다. 정보 검색 분야에서 질의와 문서에 대한 다양한 표현 기법들이 제안되어 왔으며, 또한 이들에 대응하는 많은 검색 기법들이 개발되어 왔다. 최근 보다 높은 검색 효과를 얻기 위하여 질의와 문서에 대해 다양한 표현 방법을 사용하거나 여러 가지의 검색 기법을 사용하여 서로 다른 집합의 문서들을 검색하고, 그 결과들을 결합하는 연구가 진행되어 왔으며, 이와 관련된 연구들은 “데이터 퓨전(data fusion)”이라는 용어에 의해 지칭되어 있다.

McGill, et al.(1979)는 동일한 정보 요구에 대한 표현 방법에 따라, 즉 서로 다른 사용자가 문서를 검색하거나 또는 통제어 사용 여부에 따라 상이한 문서들이 검색됨을 발견하였다. Katzer, et al.(1982)는 질의 표현 방법 대신에 문서 표현 방법이 검색 효과에 미치는 영향을 조사하였으며, 서로 다른 문서 표현을 사용한 검색들이 매우 상이한 문서들을 검색함을 발견하였다. 이러한 결과들은 결합된 검색 실행의 결과가 각각의 검색 실행의 결과에 비하여 많은 적합 문헌을 포함함으로써 보다 높은 재현율을 제공할 수 있음을 암시한다.

Saracevic & Kantor(1988)는 여러 사용자에게 동일한 정보 검색 요구에 대하여 부울 질의를 생성하도록 요청하고, 생성된 다양한 질

의를 검색에 이용하였다. 그 결과 서로 다른 질의 표현이 서로 다른 문서들을 검색함을 재확인하였다. 그러나 또한 어떠한 문서가 보다 많은 질의에 의해 검색될수록 적합 문헌으로 판단될 가능성이 증가함을 추가로 발견하였다. 만약 검색 실행들을 결합하는 방법이 보다 많은 검색 실행에 의해 검색된 문서를 선호하도록 고안된다면, 결합된 검색 실행은 보다 정확한 문서값을 생성함으로써 높은 정확률을 제공할 수 있다.

Turtle & Croft(1991)는 서로 다른 문서 또는 질의 표현을 확률적 관점에서 결합할 수 있는 추론 네트워크 검색 모델(inference nework-baded retrieval model)을 개발하였다. 이 모델은 서로 다른 표현들을 문서가 질의를 만족할 수 있는 확률을 계산하기 위한 증거로서 사용한다. Turtle & Croft는 추론 네트워크 검색 모델을 기반으로 하는 INQUERY 시스템을 개발하여, 다중 증거의 사용이 검색 효과를 증가시킴을 입증하였다. Fox & Shaw(1994)는 다양한 검색 실행들을 결합하는 방법에 대한 연구를 수행하였으며, 각각의 검색 실행에 비하여 결합된 검색 실행으로부터 보다 높은 검색 효과를 얻었다. Belkin, et al.(1993)은 서로 다른 부울 질의 표현의 연속적인 결합이 검색 효과의 연속적인 향상으로 나타남을 보였다.

위에서 언급된 연구 결과들은 다양한 검색 수행을 결합함으로써 보다 높은 검색 효과를 얻을 수 있음을 보여준다. 그러나 기존의 연구들은 단지 서로 다른 표현 방법 또는 검색 기법만을 고려하였다. Harman(1993)은 TREC-1(the first Text REtrieval

Conference)에 참가한 시스템들이 유사한 수준의 검색 효과를 제공할지라도, 매우 상이한 집합의 문서들을 검색함을 발견하였다. 이러한 발견은 서로 다른 문서들을 검색함으로써 검색 효과를 향상시킬 수 있는 또 다른 방법이 있음을 암시한다.

본 논문에서는 단일 질의 표현, 단일 문서 표현, 그리고 단일 검색 기법의 사용만으로 서로 다른 집합의 문서들을 검색할 수 있는 방법을 제안한다. 문서가 다루는 주제들의 수와 문서에 포함된 색인어들의 수에 따라 문서의 형태를 분류하고, 코사인 정규화와 최대 정규화와 같은 가중치 기법의 특성들을 기술함으로써, 이러한 특성들이 검색되는 문서들의 형태에 어떠한 영향을 미치는지를 설명한다. 또한 서로 다른 특성을 갖는 가중치 기법이 서로 다른 집합의 문서들을 검색함을 설명한다. 실험 결과, 코사인 정규화의 사용 여부가 서로 다른 집합의 문서들을 검색하는데 있어서 중요한 역할을 할 수 있었고, 코사인 정규화를 사용한 검색 실행과 코사인 정규화를 사용하지 않는 검색 실행을 결합함으로써 검색 효과의 향상을 얻을 수 있었다.

본 논문의 구성은 다음과 같다. 2장에서 실험에 사용되는 SMART 시스템에 대해 기술한다. 3장에서 문서들의 형태를 분류하고 가중치 기법들의 특성들을 분석함으로써, 서로 다른 특성의 가중치 기법들이 서로 다른 집합의 문서들을 검색함을 보인다. 4장에서 실험 결과에 대하여 기술하고, 마지막으로 5장에서 결론을 맺는다.

2. SMART 시스템

SMART 시스템은 하버드와 코넬 대학에서 35년 간에 걸쳐 개발된 시스템이다(Salton & McGill 1983). 질의와 문서는 완전히 자동화된 방법에 의해 색인되기 때문에, 데이터베이스의 구축과 질의의 생성을 위해 사람의 관여가 요구되지 않는다. 따라서 검색 결과가 데이터베이스의 특성에 비교적 독립적이고, 다양한 종류의 데이터베이스에 폭넓게 사용될 수 있는 장점을 지니고 있다.

2.1 유사도 계산

SMART 시스템은 벡터 공간 모델을 기반으로 하며, 문서와 질의 모두 다음과 같은 벡터로 표현된다(Salton 1989).

$$d = (w_{i1}, w_{i2}, \dots, w_{in})$$

여기서 d 는 문서 또는 질의를 표현하고, w_{ik} 는 문서 d 에서 색인어 t_k 의 가중치이다. 특정 문서에 나타나지 않는 색인어들에 대해 가중치 0이 할당된다. SMART 시스템에서 이러한 벡터들은 다음과 같은 텍스트 변환에 의해 생성된다.

- ① 텍스트로부터 단어들을 인식한다.
- ② 색인어로서 가치가 없는 불용어들을 제거한다.
- ③ 접미사들을 제거함으로써 어근들을 추출한다.
- ④ 각각의 어근들에 가중치를 부여한다.

문서 또는 질의에 대한 벡터들이 형성된 이후의 검색 과정은 벡터들의 연산에 의해 이루-

어진다. 문서 d 가 $(w_{d1}, w_{d2}, \dots, w_{dn})$ 로 표현되고, 질의 q 가 $(w_{q1}, w_{q2}, \dots, w_{qn})$ 로 표현되었을 때, 문서 d 와 질의 q 사이의 유사도를 의미하는 문서 d 의 문서값은 다음과 같이 두 벡터들의 내적으로 계산된다.

$$Sim(d, q) = \sum_{i=1}^n (w_{di} \times w_{qi})$$

문서값은 색인어들의 가중치에 의해 결정되기 때문에 가중치 부여 기법은 검색 효과에 영향을 미치는 중요한 요소이다.

2.2 가중치 부여 기법

정보 검색에 관한 많은 연구들은 색인어에 가중치를 부여하기 위하여 출현 빈도(term frequency), 장서 빈도(collection frequency)

cy), 정규화(normalization)의 세 가지 요소를 고려한다(Salton & Buckley 1988). 출현 빈도는 문서내에서 자주 출현하는 색인어에 보다 높은 가중치를 부여한다. 장서 빈도는 전체 문서들 중에서 적은 수의 문서에 출현하는 색인어에 보다 높은 가중치를 부여한다. 그리고 정규화는 데이터베이스 내의 모든 문서 벡터들의 길이를 일치시키는 요소로서, 작은 크기의 문서들이 문서값 계산에 있어서 불공정하게 취급되는 것을 피하도록 한다. <표 1>은 각각의 구성 요소에 대해 잘 알려진 공식들을 보여준다.

문서와 질의를 표현하는 벡터의 색인어들에 가중치를 부여하는 방법은 앞에서 언급된 세 가지 요소의 조합으로 구성된다. 예를 들어, $lnc \cdot ltc$ 는 문서 벡터와 질의 벡터의 색인어들

<표 1> 색인어 가중치 부여 기법의 구성 요소

출현빈도(term frequency)	
n	1.0
t	색인어의 출현 빈도를 무시하고 벡터를 구성하는 색인어에 1의 가중치 부여
a	$0.5 + 0.5 \frac{tf}{\max tf}$ 문서나 질의내에서 색인어의 출현 빈도 보강된 정규화 출현 빈도(t 를 $\max tf$ 로 나누고, 그 결과가 0.5 ~1.0의 값을 갖도록 정규화)
l	$\ln tf + 1.0$ 색인어의 출현 빈도에 로그 함수 적용 색인어의 출현 빈도(b, n, a, l)만으로 가중치 생성
장서 빈도(collection frequency)	
n	1.0
t	$\ln \frac{N}{n}$ 색인어 출현 빈도와 역문헌 빈도를 곱한다(N 은 전체 문서들의 수이며, n 은 그 색인어를 포함하고 있는 문서들의 수이다.)
정규화(normalization)	
n	1.0 출현 빈도와 장서 빈도만으로 유도된 가중치를 사용
c	$\sqrt{\frac{1}{\sum w_i^2}}$ 유클리디안 벡터 길이를 이용한 코사인 정규화

에 대해서 각각 *Inc*와 *IIC* 기법을 적용함을 의미한다. 즉, 색인어 출현 빈도의 로그 값을 코사인 정규화함으로써 문서 벡터의 색인어들에 가중치를 부여하고, 색인어 출현 빈도와 역 문헌 빈도(inverse document frequency)를 곱한 값을 코사인 정규화함으로써 질의 벡터의 색인어들에 가중치를 부여한다.

3. 가중치 기법들에 대한 분석

3.1 문서 형태 분류

출현빈도벡터길이(tf-vector length)는 출현 빈도의 합으로 정의된다. t_i 가 색인어의 출현 빈도이고, n 이 벡터를 구성하는 색인어들의 수일 때, 출현빈도벡터 길이는 $\sum_{i=1}^n tf_i$ 이다. 예를 들면, 문서 d_1 이 색인어와 가중치의 쌍으로 다음과 같이 표현되었다고 가정하자.

$$d_1 = \{(t_1, 1), (t_2, 2), (t_3, 3), (t_4, 4), (t_5, 5)\}$$

이때 문서 d_1 의 출현빈도벡터길이는 15 ($= 1 + 2 + 3 + 4 + 5$)이다. 한편, 문서 길이 (document length)는 일반적으로 문서에 나타나는 모든 단어들의 출현빈도의 합으로 정의된다. 많은 현실적인 문서집합에서 문서들은 매우 다양한 출현빈도벡터길이를 갖는다. 문서들은 출현빈도벡터길이에 따라 다음과 같이 3 가지 형태로 분류된다(Lee 1995).

- 짧은 출현빈도벡터길이

(short tf -vector length)

- 중간 출현빈도벡터길이

(median tf -vector length)

- 긴 출현빈도벡터길이

(long tf -vector length)

많은 경우에 긴 문서뿐만 아니라 짧은 문서들도 단일 주제가 아닌 다중 주제를 기술하는 것으로 알려져 왔다(Moffat et al. 1994; Callan 1994). 따라서 문서들은 문서가 다른 주제들의 수에 따라 다음과 같이 2가지 형태로 분류될 수 있다.

- 단일 주제(single topic)

- 다중 주제(multiple topic)

3.2 가중치 기법의 특성

출현빈도벡터길이를 정규화하지 않는 가중치 기법이 사용되었을 때, 긴 출현빈도벡터길이의 문서는 짧은 출현빈도벡터길이를 갖는 문서에 비하여 높은 검색 가능성을 갖는다. 예를 들면, 문서 d_2 , d_3 가 다음과 같이 표현되어 있다고 가정하자.

$$d_2 = \{(t_1, 1), (t_2, 1), \dots, (t_n, 1)\}$$

$$d_3 = \{(t_1, 2), (t_2, 2), \dots, (t_n, 2)\}$$

출현빈도벡터길이 정규화 요소를 포함하지 않는 가중치 기법 ln ($\ln tf + 1.0$)이 사용된다면, $d_{2,ln}$ 의 색인어 가중치는 $d_{3,ln}$ 의 색인어 가중치보다 높다.

$$d_{2,ln} = \{(t_1, 1), (t_2, 1), \dots, (t_n, 1)\}$$

$$d_{3,ln} = \{(t_1, 1.69), \dots, (t_n, 1.69)\}$$

따라서 질의 $q1 = \{(t_1, w_1), (t_2, w_2), \dots, (t_n, w_n)\}$ 에 대한 $d_{2,ln}$, $d_{3,ln}$ 의 유사도는 다음

과 같은 관계를 갖는다.

$$\text{Sim}(d_{2, \text{inc}}, q_1) \cdot 1.69 = \text{Sim}(d_{3, \text{inc}}, q_1)$$

즉, 긴 출현빈도벡터길이를 갖는 문서 d_2 의 유사도가 짧은 출현빈도벡터길이를 갖는 문서 d_3 유사도의 1.69배이다. 그러나 출현빈도벡터길이를 고려할 때, 문서 d_2 와 d_3 는 거의 동일한 문서로 간주될 수 있다.

일반적으로 검색의 목적하에서 모든 문서는 동등하게 취급되어야 한다. 그러나 앞에서 설명된 바와 같이 출현빈도벡터길이에 대한 정규화가 가중치 기법에 고려되지 않는다면, 검색 시스템은 긴 출현빈도벡터길이를 갖는 문서를 선호한다. SMART 시스템의 가중치 기법에서 사용되는 코사인 정규화는 출현빈도벡터길이를 정규화하는 특성을 지니고 있으며, 많은 경우에 코사인 정규화를 하는 가중치 기법이 코사인 정규화를 하지 않는 가중치 기법보다 높은 검색 효과를 제공하는 것으로 알려져 있다.

코사인 정규화는 출현빈도벡터길이를 정규화하는 바람직한 특성을 지니고 있다 할지라도, 다중 주제를 다루는 적합문서의 검색을 어렵게 하는 특성을 지니고 있다. 이는 사용자 질의와 관련된 적합 색인어의 가중치가 비적합 색인어 가중치에 의해 감소되기 때문이다. 예를 들면, 문서 d_4 가 단일 주제만을 다루고, 문서 d_5 는 문서 d_4 가 기술하는 주제를 포함하여 여러개의 주제를 다룬다고 가정하자. 즉, 문서 d_4, d_5 는 다음과 같이 표현될 수 있다.

$$d_4 = \{(t_1, 1), (t_m, 1), \dots, (t_n, 1)\}$$

$$d_5 = \{(t_1, 2), (t_m, 2), \dots, (t_n, 2)\}$$

가중치 기법 inc 가 적용된다면, 문서 d_4, d_5

는 다음과 같이 변환된다.

$$d_{4, \text{inc}} = \{(t_1, \frac{1}{\sqrt{m}}), (t_m, \frac{1}{\sqrt{m}}), (t_{m+1}, 0), \dots, (t_n, 0)\}$$

$$d_{5, \text{inc}} = \{(t_1, \frac{1}{\sqrt{n}}), (t_m, \frac{1}{\sqrt{n}}), (t_{m+1}, \frac{1}{\sqrt{n}}), \dots, (t_n, 0)\}$$

따라서 질의 $q_2 = \{(t_1, w_1), \dots, (t_m, w_m), (t_{m+1}, 0), \dots, (t_n, 0)\}$ 에 대한 $d_{4, \text{inc}}$ 의 유사도는 다음과 같다.

$$\begin{aligned} \text{Sim}(d_{4, \text{inc}}, q_2) &= \left\{ \frac{1}{\sqrt{m}} \cdot w_1 + \dots + \frac{1}{\sqrt{m}} \cdot w_m \right. \\ &= \frac{1}{\sqrt{m}} \cdot \sum_{i=1}^m w_i \end{aligned}$$

$$\begin{aligned} \text{Sim}(d_{5, \text{inc}}, q_2) &= \left\{ \frac{1}{\sqrt{n}} \cdot w_1 + \dots + \frac{1}{\sqrt{n}} \cdot w_m \right. \\ &= \frac{1}{\sqrt{n}} \cdot \sum_{i=1}^m w_i \end{aligned}$$

n 이 항상 m 보다 크기 때문에, 단일 주제 문서 d_4 가 다중 주제 문서 d_5 보다 높은 순위를 부여받는다. 그러나 문서 d_4, d_5 는 질의 q_2 에 대하여 같은 양의 정보를 포함하고 있다. 이처럼 바람직하지 않은 결과는 문서 d_5 에 포함되어 있는 적합 색인어 $t_1 \sim t_m$ 의 가중치가 비적합 색인어 $t_{m+1} \sim t_n$ 의 가중치에 의해 감소되기 때문이다.

a 로 표기되는 보강된 정규화 출현 빈도는 출현 빈도 tf 를 최대 출현 빈도 $\max tf$ 로 정규화 한다. 이러한 최대 정규화는 특정 경우에 출현 빈도벡터길이를 정규화할 수 있다. 예를 들면, 문서 d_6, d_7 이 다음과 같이 표현되어 있다고 가정하자.

$$d_6 = \{(t_1, 1), (t_2, 1), \dots, (t_n, 1)\}$$

$$d_7 = \{(t_1, 2), (t_2, 2), \dots, (t_n, 2)\}$$

가중치 기법 $ann(0.5 + 0.5 \frac{tf}{\max tf})$ 이 적용된다면, 문서 d_6, d_7 은 다음과 같이 동일한 벡터 표현을 갖는다.

$$d_{6,ann} = \{(t_1, 1), (t_2, 1), \dots, (t_n, 1)\}$$

$$d_{7,ann} = \{(t_1, 1), (t_2, 1), \dots, (t_n, 1)\}$$

그러나 이러한 최대 정규화는 많은 경우에 출현빈도벡터길이를 정규화할 수 없다. 예를 들면, 문서 d_8, d_9 가 다음과 같이 표현되어 있다고 가정하자.

$$d_8 = \{(t_1, 1), (t_2, 1), \dots, (t_{100}, 1)\}$$

$$d_9 = \{(t_1, 2), (t_2, 1), \dots, (t_{100}, 1)\}$$

가중치 기법 ann 이 적용된다면, 다음과 같이 $d_{8,ann}$ 의 색인어 가중치가 $d_{9,ann}$ 의 색인어 가중치보다 크다.

$$d_{8,ann} = \{(t_1, 1), (t_2, 1), \dots, (t_{100}, 1)\}$$

$$d_{9,ann} = \{(t_1, 1), (t_2, 0.75), \dots, (t_{100}, 0.75)\}$$

따라서 임의의 질의에 대하여 문서 d_8 이 문서 d_9 보다 높은 순위를 부여받을 가능성이 크다. 그러나 색인어 t_i 의 출현 빈도만이 서로 다르기 때문에, 문서 d_8, d_9 은 거의 동일한 문서로 간주될 수 있다. 한편, 가중치 기법 inc 가 적용된다면, 문서 d_8, d_9 는 다음과 같이 변환될 수 있다.

$$d_{8,inc} = \{(t_1, 0.1), (t_2, 0.1), \dots, (t_{100}, 0.1)\}$$

$$d_{9,inc} = \{(t_1, 0.17), (t_2, 0.99), \dots, (t_{100}, 0.99)\}$$

색인어 t_i 의 가중치를 제외한다면 $d_{8,inc}$ 의 색인어 가중치는 $d_{9,inc}$ 의 색인어 가중치와 거의 동일하기 때문에, 문서 d_8 과 d_9 는 임의의 질의에 대하여 유사한 수준의 유사도를 제공한다.

최대 정규화가 출현빈도벡터길이의 정규화에 있어 문제점을 가지고 있다 할지라도, 다중 주제 문서의 검색이라는 측면에서 코사인 정규화에 비하여 장점을 지니고 있다. 예를 들면, 문서 d_{10} 이 단일 주제를 다루고, 문서 d_{11} 이 문서 d_{10} 이 다루는 단일 주제를 포함한 여러 개의 주제를 기술한다고 가정하자. 즉, 문서 d_{10}, d_{11} 은 다음과 같이 표현될 수 있다.

$$d_{10} = \{(t_1, 1), \dots, (t_m, 1), (t_{m+1}, 0), (t_n, 0)\}$$

$$d_{11} = \{(t_1, 1), \dots, (t_m, 1), (t_{m+1}, 1), \dots, (t_n, 1)\}$$

가중치 기법 ann 이 적용된다면, 문서 d_{10}, d_{11} 은 다음과 같이 변환된다.

$$d_{10,ann} = \{(t_1, 1), \dots, (t_m, 1), (t_{m+1}, 0), \dots, (t_n, 0)\}$$

$$d_{11,ann} = \{(t_1, 1), \dots, (t_m, 1), (t_{m+1}, 1), \dots, (t_n, 1)\}$$

따라서 질의 $q_3 = \{(t_1, 1), \dots, (t_m, w_m), (t_{m+1}, 0), \dots, (t_n, 0)\}$ 에 대하여, 문서 d_{10}, d_{11} 은 다음과 같이 동일한 문서값을 부여받는다.

$$\text{Sim}(d_{10,ann}, q_3) = \text{Sim}(d_{11,ann}, q_3) = \sum_{i=1}^m w_i$$

비록 일반적이지 않을지라도, 위의 예는 코사인 정규화의 문제점이 최대 정규화에 의해 완화될 수 있음을 보여준다.

지금까지 검색되는 문서 형태에 영향을 주는 코사인 정규화, 최대 정규화와 같은 가중치 기법의 중요한 특성을 설명하였다. 이러한 특성에 근거하여 가중치 기법은 다음과 같이 분류된다.

〈표 2〉 서로 다른 가중치 기법을 사용하는 두개의 검색실행에 의해 공통적으로 검색 되는 문서들의 수(WSJ.D2:상위 순위 200개 문서가 100개의 질의에 의해 검색됨)

	lnc · ltc(C)	anc · ltc(C)	anc · ltc(C)	ltn · ntc(n)	ann · ntc(M)
anc · ltc(C)	15183	—	—	—	—
lnn · ntc(N)	9911	8200	—	—	—
ltn · ntc(N)	10573	9032	15937	—	—
ann · ntc(M)	10106	10395	13069	13310	—
atn · ntc(M)	10301	10301	11745	13733	16069

- 부류 C: 코사인 정규화를 수행하는 가중치 기법들
- 부류 M: 최대 정규화를 수행하고 코사인 정규화를 수행하지 않는 가중치 기법들
- 부류 N: 코사인 정규화와 최대 정규화 모두를 수행하지 않는 가중치 기법들

앞에서 설명된 바와 같이, 서로 다른 부류에 속하는 가중치 기법들은 서로 다른 형태의 문서들을 검색할 수 있다. 이를 확인하기 위하여 서로 다른 가중치 기법을 사용하는 두개의 검색 실행에 의해 공통적으로 검색되는 문서들의 수를 조사하였다. 〈표 2〉는 같은 부류에 속하는 가중치 기법들에 의해 보다 많은 수의 문서들이 공통적으로 검색됨을 보여준다. 또한 코사인 정규화의 사용 여부가 서로 다른 집합의 문서들을 검색하는데 중요한 역할을 할 수 있다.

4. 성능 평가

정보검색 시스템의 검색 효과는 일반적으로

재현율과 정확률로서 평가된다(Salton & McGill 1993). 재현율은 문서 집합에서 사용자가 원하는 문서를 어느 정도 검색하였는가를 나타내고, 정확률은 검색된 문서들 중에서 사용자가 원하는 문서가 얼마나 포함되어 있는가를 나타낸다. 예를 들면, 전체 문서 집합에 200개의 문서가 저장되어 있고, 이 문서 집합속에 사용자가 입력한 질의에 관련된 문서가 5개 있다고 가정하자. 이때 사용자가 검색 시스템을 사용하여 6개의 문서를 검색하였고 검색된 문서 중에서 4개의 문서가 질의에 관련된 문서라고 하면, 재현율과 정확률은 각각 0.8과 0.67이 된다. 문서 순위 결정 방법을 제공하는 검색 시스템은 보간 기법을 사용하여 고정된 재현율에 대한 정확률을 계산할 수 있다. 본 논문에서는 고정된 11개의 재현율(0.0, 0.1, …, 1.0)에 대한 모든 질의의 정확률을 평균한 값을 나타내는 11-포인트 평균 정확률을 이용하여 검색 효과를 측정하였다.

본 장에서는 WSJ.D2 자료 집합(Harman 1994)으로 서로 다른 가중치기법을 사용하는 다양한 검색 실행을 수행하여 그 결과를 결합

<표 3> 서로 다른 가중치 기법을 사용하는 검색 실행의 결합

	lnc · ltc(C) 0.3284	anc · ltc(C) 0.3034	lnn · ntc(N) 0.2661	ltn · ntc(N) 0.3228	atn · ntc(M) 0.3002
anc · ltc(C) 0.3034	0.3205 (-2.4%)	—	—	—	—
lnn · ntc(N) 0.2661	0.3378 (+2.9%)	0.3433 (+13.1%)	—	—	—
ltn · ntc(N) 0.3028	0.3464 (+5.5%)	0.3517 (+15.9%)	0.2887 (-4.7%)	—	—
atn · ntc(M) 0.3002	0.3575 (+8.9%)	0.3473 (+14.5%)	0.2982 (-0.7%)	0.3162 (+4.4%)	—
atn · ntc(M) 0.3198	0.3627 (+10.4%)	0.3451 (+7.9%)	0.3130 (-2.2%)	0.3217 (+0.6%)	0.3148 (-1.6%)

한다. 상위 순위 200개 문서들이 검색 실행과 결합된 검색 실행의 결과로서 검색되었다. 사용된 검색 실행의 결합 방법은 다음과 같다 (Lee 1995). 첫째, 각각의 검색 실행이 생성한 문서값을 그 검색 실행이 생성한 최대 문서값으로 나눈다. 둘째, 결합된 검색 실행에서 각각의 문서에 대한 문서값은 결합에 참가하는 검색 실행들이 그 문서에 대해 생성한 문서값들의 합이다.

서로 다른 가중치 기법을 사용하는 6개의 검색 실행을 수행하고, 그들의 쌍들을 결합하였다. <표 3>은 그 결과를 보여준다. % 변화는 각 쌍에서 높은 검색 효과를 보이는 검색 실행에 대하여 계산되었다. <표 2>와 <표 3>의 비교로부터 결합되는 검색 실행이 유사한 검색 효과를 제공하고 상이한 문서들을 검색할수록, 그들의 결합으로부터 얻을 수 있는 검색 효과의 향상이 큼을 알 수 있다. 또한 <표 3>은 부류 C에 속하는 가중치 기법과 다른 부류에

속하는 가중치 기법 사이의 결합에 대해서만 의미있는 검색 효과의 향상을 얻을 수 있음을 보여준다. 즉, 서로 다른 2개의 검색 실행의 결합시에, 다음과 같은 조건하에서 의미있는 검색 효과의 향상을 얻을 수 있다.

- 결합되는 검색 실행은 유사한 수준의 검색 효과를 제공한다.
- 하나의 검색 실행의 가중치 기법은 코사인 정규화를 수행하고, 다른 하나의 검색 실행의 가중치 기법은 코사인 정규화를 수행하지 않는다.

5. 결 론

지금까지 다양한 질의 및 문서 표현법과 검색 기법들이 정보 검색 분야에서 개발되었다. 최근 이러한 방법들을 결합하기 위한 연구들이

수행되었으며, 서로 다른 검색 실행들의 결합으로 보다 높은 검색 효과를 얻을 수 있음이 확인되었다. 본 논문에서는 서로 다른 가중치 기법을 사용하는 검색 실행을 결합함으로써 보다 높은 검색 효과를 얻을 수 있는 방법을 제안하였다. 출현빈도벡터길이와 문서가 기술하는 주제의 수에 따라 문서의 형태를 분류하고, 코사인 정규화와 최대 정규화와 같은 가중치 기법의 특성들을 설명하였다. 또한, 문서형태와 가중치 기법의 특성을 기반으로 하여 서로 다른 형태의 문서들이 서로 다른 특성의 가중치 기법에 의해 검색될 수 있음을 설명하였다. 제안하는 방법은 문서 및 질의의 단일 표현과 단일 검색 기법을 사용하는 시스템에 쉽게 수용될 수 있다.

참 고 문 헌

- Belkin, N.J., Cool, C., Croft, W.B., & Callan, J.P. (1993). The effect of multiple query representations on information retrieval performance. Proceedings of the 16th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, 339-346.
- Callan, J.P. (1994). Passage-level evidence in document retrieval. Proceedings of the 17th Annual International ACM SIGIR Conference on Research and Develop-

- opment in Information Retrieval, 302-310.
- Fox, E.A., & Shaw, J.A. (1994). Combination of multiple searches. Proceedings of the 2nd Text REtrieval Conference (TREC-2), National Institute of Standards and Technology Special Publication 500-215, 243-252.
- Harman, D. (1993). Overview of the 1st text retrieval conference. Proceeding of the 16th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, 36-48.
- Harman, D. (1994). Overview of the second text retrieval conference. Proceedings of the 2nd Text REtrieval Conference (TREC-2), National Institute of Standards and Technology Special Publication 500-215, 243-252.
- Katzer, J., McGill, M.J., Tessier, J.A., Frakes, W., & Dasgupta, P. (1982). A study of the overlap among document representations. Technology: Research and Development, 1(2), 261-274.
- Lee, J.H. (1995). Combining Multiple Evidence from Different Properties of Weighting Schemes. Proceedings of the 18th Annual

- International ACM SIGIR Conference on Research and Development in Information Retrieval, 180-188.
- McGill, M., Koll, M & Norreault, T. (1979). An evaluation of factors affecting document ranking by information retrieval systems. Syracuse, Syracuse University School of Information Studies.
- Moffat, A., Sacks-Davis, R., Wilkinson, R., & Zobel, J. (1994). Retrieval of partial documents. Proceedings of the Second Text REtrieval Conference (TREC-2), National Institute of Standards and Technology Special Publication 500-215, 181-190.
- Salton, G., & McGill, M.J. (1983). Introduction to Modern Information Retrieval. McGraw-Hill, Inc.
- Salton G., & Buckley, C.(1988). Term weighting approaches in automatic text retrieval. *Information Processing and Management*, 24 (5), 513-523.
- Salton, G. (1989). Automatic Text Processing – the Transformation, Analysis and Retrieval of Information by Computer, Addison – Wesley Publishing Co., Reading MA.
- Saracevic, T., & Kantor, P. (1988). A study of information seeking and retrieving. III. Searchers, searches, overlap. *Journal of the American Society for Information Science*, 39(3), 197-216.
- Turtle, H., & Croft, W.B. (1991). Evaluation of an inference network-based retrieval model. *ACM Transactions on Information Systems*, 9(3), 187-222.