

---

# 적합성 피드백을 이용한 웹 문서검색에 관한 연구

김영천\*, 이성주\*

A Study on Document Retrieval of Web Using Relevance Feedback

Young-cheon kim, Sung-joo Lee

## 요 약

정보검색에서 순수한 부울 검색 시스템은 문서와 질의 사이의 유사도를 나타내는 문서값을 계산할 수 없기 때문에, 검색된 문서들을 질의를 만족하는 정보에 따라 정렬할 수 없다. 부울 검색 시스템의 이러한 단점을 보완하는 방법으로 MMM 모델, Paice 모델, P-norm 모델이 개발되었다. 이러한 방법들은 부울 연산자를 유연하게 연산하는 공통된 특성을 지니고 있다. 본 논문에서는 높은 검색 효과를 제공하는 질의분해 적합성 피드백(QSRF)을 이용한 정보 검색 모델을 제안한다. 질의 분해 적합성 피드백 모델의 연산 특성이 MMM, Paice, P norm 모델보다 우수함을 설명하고, 또한 성능 비교를 통하여 이를 입증한다.

## ABSTRACT

In conventional boolean retrieval systems, document ranking is not supported and similarity coefficients cannot be computed between queries and documents. The MMM, Paice and P-norm models have been proposed in the past to support the ranking facility for boolean retrieval systems. They have common properties of interpreting boolean operators softly. In this paper we propose a new soft evaluation method for Information retrieval using query splitting relevance feedback model. We also show through performance comparison that query splitting relevance feedback(QSRF) is more efficient and effective than MMM, Paice and P-norm.

**Keyword :** 정보검색, 적합성 피드백, 질의 분해, 부울 검색, 유사도

---

\* 조선대학교

접수일자 : 2001년 2월 26일

## I. 서론

정보검색에서 가장 중요하면서도 어려운 문제 중의 하나는 사용자가 원하는 정보를 찾기 위한 효율적인 질의를 작성하는 일이다. 하지만 전체 문서 집합의 구성에 대해 미리 알고 있지 않는 한 이상적인 최적의 질의는 작성할 수 없다. 대신 최초에는 시험적 질의(tentative query)로 검색을 수행한 후, 이전의 검색 결과에 대한 평가에 기반 하여 다음 번 검색의 질의를 개선시키는 방법이 적합성 피드백(relevance feedback)이다[1].

적합성 피드백은 특정 질의와 적합한 문서들은 유사한 벡터로 표현된다고 가정한다. 따라서, 어떤 문서가 주어진 질의에 적합하다고 판단되면 질의를 적합한 문서와의 유사도가 증가하도록 변환하여 질의를 개선시킨다. 이렇게 개선된 질의는 최초 적합하다고 판단된 문서와 유사한 문서들을 추가적으로 검색하여 더 많은 양의 적합 문서를 검색해 낼 수 있다.

실제 이 적합성 피드백을 이용할 때에는 전체 문서집합에 대해 적합문서와 부적합문서를 미리 알 수 없으므로, 이미 적합성이 알려져 있는 문서들의 정보에 기반 하여 질의확장을 수행한다. 이때의 적합성을 사용자가 알려주는 방법을 사용자 적합성 피드백(user relevance feedback)이라 하고, 사용자의 개입 없이 초기질의로 검색된 결과 문서 중 상위 문서를 적합한 문서로 간주하여 적합성 피드백을 적용하는 방법을 의사 적합성 피드백(pseudo relevance feedback)이라 한다[2],[3],[4].

본 논문에서는 질의 분해 적합성 피드백 모델을 제안한다. 본 논문의 구성은 다음과 같다. 2장에서는 부울 연산자를 유연하게 연산하는 기준의 방법들 MMM, Paice, P-norm 모델, 적합성 피드백에 대하여 기술한다. 3장에서는 높은 검색 효과를 제공하는 질의 분해 적합성 피드백 모델을 제안한다. 4장에서는 질의 분해 적합성 피드백 모델과 MMM, Paice, P-norm 모델의 성능을 비교한다. 마지막으로 5장에서 결론 및 앞으로의 연구 방향을 제시한다.

## II. 부울 연산자를 유연하게 연산하는 기준의 방법

순수한 부울 검색 모델은 문서와 질의 사이의 유사도를 나타내는 문서값을 계산할 수 없기 때문에, 검색된 문서들을 질의를 만족하는 정도에 따라 정렬할 수 없다는 단점을 지니고 있다.

순수한 부울 검색 시스템의 단점을 보완하기 위하여 퍼지 집합 모델(Fuzzy Set Model)이 개발되었다. 퍼지 집합 모델은 색인어가 문서 내에서 갖는 중요성을 반영하는 색인어 가중치를 이용하여 문서값을 계산함으로써 부울 검색 시스템의 문제점을 극복하였다. 그러나 퍼지 집합 모델은 많은 경우에 부정확한 문서값을 생성하기 때문에 정보 검색 모델로서 부적합하다고 비판되어 왔다. 이것은 AND와 OR 연산을 위하여 사용하는 MIN과 MAX 연산자가 단일 피연산자 의존 문제(Single Operand Dependency Problem)를 발생시키기 때문이다[5],[6].

퍼지 집합 모델의 단일 피연산자 의존 문제를 극복하기 위해 MMM 모델, Paice 모델, P-norm 모델이 개발되었다. 이를 모델들은 AND와 OR 연산을 위하여 MIN과 MAX 대신에 부울 연산자를 유연하게 연산하는 새로운 연산자를 사용함으로써 퍼지 집합 모델, MMM 모델, Paice 모델, P-norm 모델을 기반으로 하는 정보 검색 시스템은  $\langle T, Q, D, F \rangle$ 로 정의되는 확장된 부울 검색 체계(Extended Boolean Retrieval Framework) 내에서 설명될 수 있다.

- ① T는 질의와 문서를 표현하기 위해 사용되는 색인어들의 집합이다.
- ② Q는 시스템이 인식할 수 있는 질의들의 집합이다. Q에 속하는 각각의 질의  $q_i$ 는 색인어들과 부울 연산자 AND, OR, NOT으로 구성된 부울 수식이다.
- ③ D는 문서들의 집합이다. D에 속하는 각각의 문서  $d_j$ 는  $w_{ij}$ 가 색인어  $t_i$ 의 가중치일 때,  $\{(t_i, w_{ij}), \dots, (t_n, w_{nj})\}$ 와 같이 표현된다. 색인어 가중치  $w_{ij}$ 는 0부터 1사이의 값을 갖는다.

- ④ F는 문서값을 계산하는 순위 결정 함수(Ranking Function)로서 다음과 같이 정의된다.

$$F: D \times Q \rightarrow [0, 1]$$

검색함수 F는 각 쌍의 (d, q)에 0부터 1사이의 값을 지정한다. 이 값은 문서 d와 질의 q사이의 유사도를 의미하며, 질의 q에 대한 문서 d의 문서값이다.

검색 함수 F(d, q)는 다음과 같은 2단계 과정을 거쳐서 계산된다.

- (i) 질의에 나타난 각각의 색인어  $t_i$ 에 대하여,  $F(d, t_i)$ 는 문서 d에서 색인어  $t_i$ 의 가중치  $w_i$ 로 정의된다.
- (ii) 부울 연산자 AND와 OR는 (a), (b), (c), (d)에서 주어진 식들을 이용하여 계산되고, NOT은  $F(d, \text{NOT } t_i) = 1 - w_i$ 로 계산된다.

두 개 이상의 부울 연산자를 포함하는 부울 질의는 가장 안쪽에 위치하는 절부터 순환적으로 계산된다.

퍼지 집합 모델의 부울 연산자 계산식 (a)는 두 개의 피연산자를 갖는 이항연산이고, MMM, Paice, P-norm 모델의 연산자 계산식은 2개 이상의 피연산자를 갖는 다항연산이다. 이것은 퍼지 집합 모델의 MIN과 MAX 연산자가 결합법칙을 만족하는 데 비하여 MMM, Paice, P-norm 모델의 연산자는 결합법칙을 만족하지 못하기 때문이다. 결합법칙을 만족하지 못할 경우, 임의의 문서에 대하여 두 개의 동일한 질의(( $t_1 \text{ AND } t_2$ ) $\text{AND } t_3$ 와  $t_1 \text{ AND } (t_2 \text{ AND } t_3)$ )의 문서값이 서로 다르다. MMM, Paice, P-norm 모델은 이러한 문제점을 다항연산을 가능하게 함으로써 극복하였다.

$$F(d, t_1 \text{ AND } t_2) = \text{MIN}(w_1, w_2) \quad \dots \dots \dots (1)$$

$$F(d, t_1 \text{ OR } t_2) = \text{MAX}(w_1, w_2) \quad \dots \dots \dots (2)$$

(a) 퍼지 집합 모델

$$\begin{aligned} F(d, t_1 \text{ AND } \dots \text{ AND } t_n) &= \\ r \cdot \text{MAX}(w_1 \dots w_n) + (1 - r) \cdot \text{MIN}(w_1 \dots w_n) & \dots \dots \dots (3) \\ 0 \leq r \leq 0.5 \dots \end{aligned}$$

$$\begin{aligned} F(d, t_1 \text{ OR } \dots \text{ OR } t_n) &= \\ r \cdot \text{MIN}(w_1 \dots w_n) + (1 - r) \cdot \text{MAX}(w_1 \dots w_n) & \dots \dots \dots (4) \\ 0.5 \leq r \leq 1 & \end{aligned}$$

(b) MMM 모델

$$F(d, t_1 \text{ AND } \dots \text{ AND } t_n) = \frac{\sum_{i=1}^n (r^{i-1} \cdot w_i)}{\sum_{i=1}^n (r^{i-1})} \quad \dots \dots \dots (5)$$

( $0 \leq r \leq 1$ ,  $w_i'$ 는 오름차순정렬)

$$F(d, t_1 \text{ OR } \dots \text{ OR } t_n) = \frac{\sum_{i=1}^n (r^{i-1} \cdot w_i)}{\sum_{i=1}^n (r^{i-1})} \quad \dots \dots \dots (6)$$

... (6)

( $0 \leq r \leq 1$ ,  $w_i'$ 는 내림차순정렬)

(c) Paice 모델

$$\begin{aligned} F(d, t_1 \text{ AND } \dots \text{ AND } t_n) &= \dots \dots \dots (7) \\ 1 - \left[ \frac{(1 - w_1)^p + \dots + (1 - w_n)^p}{n} \right]^{\frac{1}{p}} & \quad (1 \leq p \leq \infty) \end{aligned}$$

$$\begin{aligned} F(d, t_1 \text{ OR } \dots \text{ OR } t_n) &= \dots \dots \dots (8) \\ \left[ \frac{w_1^p + \dots + w_n^p}{n} \right]^{\frac{1}{p}} & \quad (1 \leq p \leq \infty) \end{aligned}$$

(d) P-norm 모델

### 1. 적합성 피드백

정보검색에서 가장 중요하면서도 어려운 문제 중의 하나는 사용자가 원하는 정보를 찾기 위한 효율적인 질의를 작성하는 일이다. 하지만 전체 문서집합의 구성에 대해 미리 알고 있지 않는 한 이상적인 최적의 질의는 작성할 수 없다. 대신 최초에는 시험적 질의(tentative query)로 검

색을 수행한 후, 이전의 검색 결과에 대한 평가에 기반하여 다음 번 검색의 질의를 개선시키는 방법이 적합성 피드백(relevance feedback)이다. 일반적인 적합성 피드백은 그림 1과 같다.

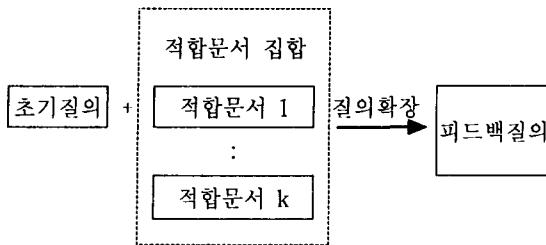


그림 1. 일반적인 적합성 피드백  
Fig. 1. General Relevance Feedback

## 2. 정규화

확장된 부울 검색 체계를 기반으로 하는 검색 모델은 문서값을 계산하기 위하여 색인어 가중치를 사용한다. 색인어 가중치는 역문헌빈도 (Inverse Document Frequency)와 색인어출현빈도(Term Frequency)로부터 유도될 수 있다. N이 문서집합을 구성하는 문서들의 수이고,  $n_k$ 가 색인어  $k$ 가 출현하는 문서들의 수일 때, 색인어  $k$ 의 역문헌빈도  $IDF_k$ 는  $\log(N/n_k)$ 로 정의된다. 색인어 출현빈도  $TF_{ik}$ 는 문서  $i$ 에서 색인어  $k$ 의 출현빈도를 의미한다. 문서  $i$ 에서 색인어  $k$ 의 색인어 가중치  $W_{ik}$ 는  $IDF_k \cdot F_{ik}$ 로 정의될 수 있다. 확장된 부울 검색 체계에서 색인어 가중치는 0부터 1 사이의 값이어야 하기 때문에  $W_{ik}$ 는 식(9)와 같이 정규화된다[7],[8],[9].

$$W_{ik} = \frac{\frac{TF_{ik}}{\max TF \text{ in document } i}}{\frac{IDF_k}{\max IDF \text{ in document }}} \quad (2)$$

## III. 질의 분해 적합성 피드백 모델

문서의 제목과 내용 문장만을 시스템의 입력으로 준다. 입력된 문서에 대해의 한국어 품사태거를 이용하여 명사만 추출한 후 벡터를 구성

한다. 이 때 벡터의 가중치를 어떻게 부여할 것인지를 결정하기 위해 가중치 사이의 성능 실험을 하였다.

실험 대상이 되는 가중치 부여 방법은 이진벡터( $TF_{bin}$ ), 문자내에서의 단어의 빈도로 벡터를 구성하는 방법( $TF$ ), 그리고 정규화(normalization)시 켜서 벡터를 구성하는 방법( $TF_{norm}$ ) 등이 있다. 문장벡터가 다음과 같이 구성된다고 하면,  $S_j = (w_{1j}, w_{2j}, \dots, w_{nj})$ 의 각각 가중치 부여 방법들은 다음과 같다. 이진벡터( $TF_{bin}$ )는 식(10)과 같다.

$$w_{ij} = \begin{cases} 1 & (\text{단어 } i \text{가 문장 } S_j \text{에 나타나며}) \\ 0 & (\text{otherwise}) \end{cases} \quad (10)$$

단어 빈도로 벡터를 구성하는 방법( $TF$ )은 식(11)과 같다.

$$w_{ij} = freq_i \quad (11)$$

정규화시 켜서 벡터를 구성하는 방법( $TF_{norm}$ )은 식(12)와 같다.

$$w_{ij} = \frac{freq_{ij}}{\max freq_i} \quad (12)$$

$freq_{ij}$ 는 단어  $i$ 의 문장  $S_j$ 에서의 출현 빈도를,  $\max freq_i$ 는 문서  $S_j$ 에서 출현한 단어 중 최대 빈도를 의미한다.

### 1. 질의분해 적합성 피드백

적합 문서를 이용하여 양성 피드백(Positive Feedback)으로 초기질의를 확장해 나간다. 이 때 질의 확장을 이용한 기존의 문서 검색에서는 그림 1에서처럼  $k$ 개의 문서를 통합하여 초기질의를 확장하는데 사용한다. 따라서 질의확장이 적용된 후의 질의는 여전히 하나만 남게 된다. 이 경우 적합문서에 노이즈가 섞일 가능성성이 크며, 이 적합문서를 이용해 질의확장을 적용할 경우 너무 포괄적인 질의로 확장이 된다.

이 문제를 완화하기 위해서 본 시스템에서는

통합하여 하나의 질의로 확장하지 않고 그림 2와 같이 k개의 적합문서들에 대해 각각 개별적으로 질의확장을 수행하여 k개의 피드백 질의를 생성한다. 이렇게 질의를 분해함으로써 노이즈 문서에 대해 좀더 배타적인 정보검색을 할 수 있다.

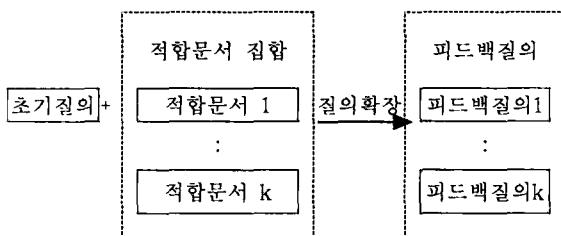


그림 2. 질의분해 적합성 피드백

Fig. 2. Query Splitting Relevance Feedback

적합성 피드백을 통해 질의를 확장해 가는 과정은 Ide Dec Hi의 식(13)과 같이 표현할 수 있다[1].

$$Q^{\text{new}} = \alpha Q^{\text{old}} + \beta \sum_{D_i \in R} D_i - \gamma \max_{n, r}(D_i) \quad \dots \dots (13)$$

여기서  $Q^{\text{new}}$ 는 새로 확장된 피드백 질의 벡터를 나타내고,  $Q^{\text{old}}$ 는 확장되기 전 단계의 질의 벡터를 의미한다.

$\max_{n, r}(D_i)$ 는 부적합문서 중 최상위 문서를 나타내며,  $\alpha$ ,  $\beta$ ,  $\gamma$ 는 이전 단계의 질의, 적합문서집합, 부적합문서집합 간의 중요도를 조율하는 상수이다. 질의를 확장하는데 적합문서는 모두 사용하지만 부적합문서에 대해서는 최상위 문서 하나만 사용하는 방법이다.

특히  $\gamma=0$ 인 경우, 즉 부적합문서집합의 정보는 사용하지 않고 적합문서 집합의 정보만을 사용하여 질의확장을 하는 경우를 양성 피드백(positive feedback)이라 한다. 양성 피드백은 의사 적합성 피드백에 자주 이용된다.

## 2. 적합 문서 추출

초기질의와 각 문서 사이의 유사도 계산은 정보검색에서 많이 사용하는 코사인 유사도(cosine

similarity) 식 (14)을 이용한다.

$$\text{sim}(S_j, Q^0) = \frac{S_j \cdot Q^0}{|S_j| \times |Q^0|} =$$

$$\frac{\sum_{i=1}^t w_{ij} \times w_{iq}}{\sqrt{\sum_{i=1}^t w_{ij}^2} \times \sqrt{\sum_{i=1}^t w_{iq}^2}} \quad \dots \dots \dots (14)$$

여기서,  $S_j$ 는 각 문서 벡터,  $Q^0$ 는 초기질의 벡터를 의미하고,  $w_{ij}$ 와  $w_{iq}$ 는 단어  $i$ 가 각각 문서와 초기질의에서 갖는 가중치이다.  $t$ 는 각 문서 벡터와 초기질의 벡터를 생성하는데 사용된 단어의 총 개수이다. 식 (14)에 의한 유사도 값에 따라 문서를 내림차순 정렬한 후 유사도 값이 큰 상위  $k$ 개의 문서를 적합 문서로 간주한다.

## IV. 실험 및 결과

본 논문에서는 성능 평가 자료로서 CHODIC를 사용하였다. CHODIC은 500개의 문서와 21개의 질의로 구성되어 있다. 문서와 질의 사이의 연관성 평가는 문서 제목을 기준으로 설정하였다.

정보 검색 시스템의 검색 효과는 그림 3에서 정의되는 재현능력도(Recall)와 검색정밀도(Precision)를 이용하여 평가된다.

재현능력도는 문서집합에서 사용자가 원하는 문서를 어느 정도 검색하였는가를 나타내고, 검색정밀도는 검색된 문서들 중에서 사용자가 원하는 문서가 얼마나 포함되어 있는가를 나타낸다.

예를 들어 200개의 문서로 구성된 문서 집합과 관련된 문서의 수가 5개인 질의를 가정하자. 사용자가 검색 시스템을 사용하여 6개의 문서를 검색하였을 때 검색된 문서 중에서 질의에 관련된 문서가 4개라 하면 재현능력도와 검색정밀도는 각각 0.8과 0.67이 된다.

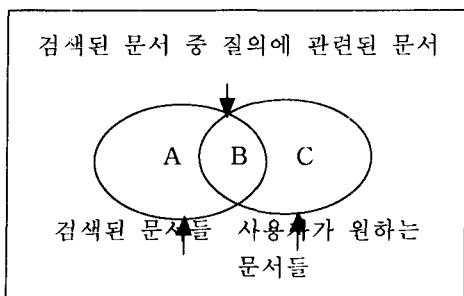


그림 3. 검색 효과 측정 방법  
Fig. 3. Measure Method of Retrieval Effect

검색정밀도(P), 재현능력도(R)는 식(17), (18)을 이용하여 측정값을 구한다.

$$P = \frac{B}{A+B} \quad \dots\dots (17)$$

$$R = \frac{B}{B+C} \quad \dots\dots (18)$$

표 1은 MMM, Paice, P-norm, RF 모델의 검색효과를 보여준다. 본 논문에서는 검색 효과를 평가하기 위하여 질의들에 대한 평균 검색정밀도를 계산한다. 각각의 질의에 대한 검색정밀도는 재현능력도를 0.25, 0.5, 0.75에 고정시켜 계산된 검색정밀도들의 평균값이다. 또한 표에 나타난 검색 효과는 가장 높은 검색 효과를 나타내는 매개변수에 대한 것이다. RF(Relevance Feedback), P-norm 모델이 MMM, Paice 모델보다 높은 검색 효과를 제공한다.

MMM 모델은 Paice 모델보다 높은 검색 효과를 나타내고 있다. 이는 색인어 가중치가 역문헌빈도와 출현빈도로부터 유도하기 때문에 검색 효과를 저하시키는 요인이 발생하기 않았기 때문이다.

표 2에서는 질의분해 적합성 피드백( Query Splitting Relevance Feedback)의 검색결과가 적합성 피드백(Relevance Feedback) 결과에 비해 검색정밀도가 3.49% 향상을 보여주고 있다.

표1. 검색 효과 비교(단위 : 검색정밀도)  
Table 1. Retrieval Effect Comparison(Unit: Precision)

모델	평균	Average
	평균	
MMM	0.327	
Paice	0.318	
P-norm	0.362	
RF	0.602	

표2. 질의 분해 피드백(단위 : 검색정밀도)  
Table 2. Query Splitting Feedback(Unit:Precision)

모델	평균	Average
	평균	
Relevance Feedback	0.602	
QSRF	0.623	

표3과 표4에서는 검색문서수를 다르게 제한했을 때 검색효율이 어떻게 달라지는가를 분석한 것이다. P-norm, 적합성 피드백(RF), 질의분해 적합성 피드백(QSRF)을 이용하여 검색문서수를 10건과 20건으로 제한한 경우 재현능력도와 검색정밀도를 보여 주고 있다.

검색문서수를 10건으로 제한하였을 때 적합성 피드백 검색 결과는 P-norm 결과에 비해 재현능력도와 검색정밀도가 각각 56%, 50% 향상되었다.

질의분해 적합성 피드백 결과는 적합성 피드백 결과에 비해 재현능력도와 검색정밀도가 각각 2.6%, 3.2%가 향상되었다.

표 3. P-norm, RF, QSRF의 재현능력도 비교

Table 3. Recall Comparison of P-norm, RF, QSRF

검색문서수	재현능력도		
	P-norm	RF	QSRF
문서수≤10	0.25	0.39	0.40
문서수≤20	0.47	0.69	0.70

검색문서수를 20건으로 제한하였을 때 적합성 피드백 검색 결과는 P-norm 결과에 비해 재현

능력도와 검색정밀도가 각각 46.81%, 48.72% 향상되었다.

질의분해 적합성 피드백 결과는 적합성 피드백 결과에 비해 재현능력도와 검색정밀도가 각각 1.45%, 5.17%가 향상되었다.

표 4. P-norm, RF, QSRF의 검색정밀도 비교  
Table 4. Precision Comparison of P-norm, RF, QSRF

검색문서수 \ 척도	검색정밀도		
	P-norm	RF	QSRF
문서수 ≤ 10	0.42	0.63	0.65
문서수 < 20	0.39	0.58	0.61

## V. 결론

정보 검색 시스템의 중요한 목적중의 하나는 단순히 사용자 질의를 만족하는 문서들의 집합을 검색하는 것이 아니라, 질의를 만족하는 정도에 따라 검색된 문서들에 순위를 부여함으로써 사용자들이 필요한 정보를 얻는데 소모되는 시간을 최소화시키는 것이다.

이러한 부울 검색 시스템의 단점을 보완하기 위해 퍼지집합 모델이 제안되었다. 그러나 퍼지집합 모델은 단일 피연산자 의존 문제로 인하여 많은 경우에 부정확한 문서값을 생성하는 것으로 알려져 왔다.

퍼지 집합 모델의 문제점을 개선하는 방법으로서 MMM 모델, Paice 모델, P-norm 모델이 개발되었다.

적합성 피드백을 통해 질의 확장은 Ide Dec Hi가 제안한 수식을 사용하였다.

본 논문에서는 정보 검색 분야에서 사용되는 적합성 피드백에 기초하여 높은 검색 효과를 제공하는 질의 분해 적합성 피드백(QSRF) 모델을 제안하였다. 실험 결과 제안하는 질의 분해 적합성 피드백 방법으로 정보검색 하는 경우가 질의 분해 적합성 피드백을 이용하지 않는 경우 보다 향상된 정밀도를 보였다.

QSRF 모델은 기존의 방법들과 비교한 결과

보다 향상된 검색 효과를 제공한다.

## 참고 문헌

- [1] Ricardo Baeza-Yates and Berthier Ribeiro-Neto, Modern Information Retrieval, Addison-Wesley Publishing Company, 1999.
- [2] Daniel Marcu, Discourse trees are good indicators of importance in text, In Inderjeet Mani and Mark Maybury, eds, Advances in Automatic Text Summarization, pp.123-136, The MIT Press, 1999.
- [3] Mark Sanderson, Accurate User Directed Summarization from Existing Tools, In Proceedings of the 7th International Conference on Information and Knowledge Management, pp.45-51, 1998.
- [4] Regina Barzilay and Michael Elhadad, Using Lexical Chains for Text Summarization, In Inderjeet Mani and Mark Maybury, eds, Advances in Automatic Text Summarization, pp.111-121, The MIT Press, 1999.
- [5] Anastasios Tombros and Mark Sanderson, Advantages of Query Biased Summaries in Information Retrieval, In Proceeding of ACM-SIGIR'98, pp.2-10, 1998.
- [6] J.H. Lee, M.H. Kim and Y.J. Lee, Information Retrieval Based on Conceptual Distance in Is-a Hierarchies, Journal of Documentation, Vol. 49, No. 2, pp.188-207, 1993.
- [7] M.H. Kim and J.H. Lee and Y.J. Lee, Analysis of Fuzzy Operators for High Quality Information Retrieval, Information Processing Letters, Vol. 46, No. 5, pp.251-256, 1993.
- [8] G.Salton, Automatic Text Processing : The Transformation, Analysis, and Retrieval of Information by Computer, Addison Wesley, 1989.
- [9] J.H.Lee, W.Y. Kim, M.H. Kim and Y.J. Lee, Enhancing the Fuzzy Set Model with Positively

Compensatory Operators, Proceedings of the 3rd International Symposium on Database Systems on Advanced Applications, Taejon, Korea, pp. 368-375, 1993.



이 성 주(Sung-Joo Lee)

1970년 : 한남대학교 물리학과(이학사)

1992년 : 광운대학교 전자계산학과  
(이학석사)

1998년 : 대구가톨릭대학교 전자계  
산학과(이학박사)

1988년~1990년 조선대학교 전자계산소 소장

1995년~1997년 조선대학교 정보과학대학장

1981년~현재 조선대학교 컴퓨터공학부 교수

※ 관심분야 : 소프트웨어 공학, 프로그래밍 언어, 객체  
지향 시스템, 러프 집합



김 영 천(Young-Chon Kim)

1992년 광주대 전자계산학과 졸업

1996년 조선대 컴퓨터공학과 졸업  
(공학석사)

1998년~현재 조선대 전자계산학과  
박사과정

※ 관심분야 : 객체지향시스템, 소프트웨어 공학, 유전  
자 알고리즘, 정보검색