

웹 탐색 성능 향상을 위한 강화학습 이용과 기준 페이지 선택 기법

(The Use of Reinforcement Learning and The Reference Page Selection Method to improve Web Spidering Performance)

이 기 철* 이 선 애**
(Kee-Cheol Lee) (Sun-Yae Lee)

요 약

웹의 세계는 하루가 다르게 확장되고 있다. 이에 따라, 지능형 정보추출 기능이 없다면 우리는 넘쳐나는 데이터 앞에서 더욱 무기력해 질 수밖에 없다. 범용 탐색 엔진을 위한 기존의 웹 검색 기법은 특정 영역이나 특정 키워드에 만 집중해야하는 특정 검색 엔진에는 너무 느린 경향이 있다. 본 논문에서는 웹 검색 능력을 개선하는 새 모델을 제시하고 실험하였다.

특정 영역과 관련된 초기의 관련 웹 페이지 집합에서 적절한 웹 페이지들을 선택하는 문제는 웹 검색 속도를 향상시키기 위해 매우 중요할 수 있다. 기준 웹 페이지 선택 기법 DOPS는 선택된 웹 페이지들이 가능한 한 직교성을 갖도록 동적으로 웹 페이지를 선택한다. 또한 새로 정의된 메저를 이용하여 적합한 기준 페이지들의 수도 결정해줄 수 있다. 매우 특화된 영역에 대한 실험을 통해서도, 본 방법은 거의 전문가 수준에 가까이 동작하였다. 전문가들이 초대형 초기 페이지 집합에 대해 일할 수 없다는 점과 그들도 기준 페이지 수의 최적치를 결정하기에 어려움을 느낀다는 점을 고려하면, 본 방법은 매우 유망하다 할 수 있다.

또한 웹 환경에 강화학습도 적용하도록 하였고, DOPS에 기반을 둔 강화학습 실험을 통해 본 방법이 하이퍼링크 수나 시간 면에서 매우 양호한 결과를 보임을 알 수 있었다.

ABSTRACT

The web world is getting so huge and untractable that without an intelligent information extractor we would get more and more helpless. Conventional web spidering techniques for general purpose search engine may be too slow for the specific search engines, which concentrate only on specific areas or keywords. In this paper a new model for improving web spidering capabilities is suggested and experimented.

How to select adequate reference web pages from the initial web page set relevant to a given specific area (or keywords) can be very important to reduce the spidering speed. Our reference web page selection method DOPS dynamically and orthogonally selects web pages, and it can also decide the appropriate number of reference pages, using a newly defined measure. Even for a very specific area, this method worked comparably well almost at the level of experts. If we consider that experts cannot work on a huge initial page set, and they still have difficulty in deciding the optimal number of the reference web pages, this method seems to be very promising.

We also applied reinforcement learning to web environment, and DOPS-based reinforcement learning experiments shows that our method works quite favorably in terms of both the number of hyper links and time.

*정회원 : 홍익대학교 컴퓨터공학과 교수

논문접수 : 2002. 2. 15.

**정회원 : 홍익대학교 컴퓨터공학과 석사과정

심사완료 : 2002. 3. 09.

본 연구는 과학재단 특정 기초 97-01-02-04-01-3으로 수행되었음.

1. 서론

최근 인터넷 상의 정보의 증가로 인해 사용자는 예전보다 더 많은 정보에 접근할 수 있는 반면, 다른 한편으로는 급속하게 늘어난 수많은 정보 중에서 자신에게 유용한 정보를 찾는데 더 많은 시간을 투자해야만 한다. 그러므로 컴퓨터가 사람을 대신하여 웹으로부터 양질의 정보를 찾아낸다면 사용자에게 매우 유용한 도구가 될 것이다. 그에 따라 웹을 포함한 인터넷에 존재하는 대규모의 전자 문서로부터 원하는 정보를 정확히 찾고 그 텍스트의 내용을 분석하여 사용자가 요구하는 정확한 정보를 제공할 수 있는 정보 분류 및 검색 기술의 개발에 대한 연구들이 진행되게 되었다. Aha[1]는 특정적인 경우들을 저장해 놓고 사용함으로써 몇몇 감독학습 알고리즘의 성능을 향상시킬 수 있는 관련 경우 기반 학습(Instance-Based Learning)을 소개하였다. Watkins[6]는 현존하는 강화학습 방법들 중 대표적으로 쓰이는 방법으로써 시간 변화에 따른 적합도 차이를 학습에 이용하는 TD-Learning의 한 종류인 Q-Learning을 소개하였는데, 이 방법은 모델의 정보없이 행동의 적합성을 나타내는 Q값만을 학습하므로 구현하기 간단하며 실제 여러 문제에 사용되어 좋은 결과를 보여주고 있다. 기본적인 Q-Learning에서는 Q값을 하나의 값으로 저장하지만, Dearden[2]는 하나의 값 대신 Q값의 분포를 탐색에 사용한다. 즉 Q값의 불확실도가 높을 경우, 낮을 경우보다 더 탐색을 함으로써 확실하지 않은 부분을 더 탐색하게 하는 방법이다. Q-Learning과 같은 기본적인 강화학습 방법은 문제의 사이즈가 커짐에 따라 성능이 매우 떨어지게 된다. 한 가지 이유는 문제가 커짐에 따라 행동과 보상간의 거리가 늘어나는 데 있다. 보상이 다시 원래 행동이 행해진 상태까지 역전과 되어 와야 하기 때문이다. 이러한 문제를 해결하기 위해 상태의 계층화가 사용된다[8]. 이러한 상태의 계층화에서는 보다 높은 단계에서 하위의 많은 단계를 건너뛰는 것이 가능하므로 행동과 보상간의 거리 문제가 커지더라도 대응이 가능하다. 그리고 Dunja Mladenic은 Yahoo 사이트에 존재하는 계층적인 웹 문서들에 대해 여러 특징 선택 방법들과 나이브 베이저안 분류 알고리즘을 이용하여 어떤 특징 선택 방법이 좀 더 나은 성능을 내는 지를 실험하였다[5].

본 논문에서는 웹 상에 존재하는 정보 중에서 특정 주제의 웹 페이지를 보다 더 정확하고 빠르게 찾는 방법을 제시한다. 2장에서는 특정 영역 검색 엔진에서 사용하는 강화학습과, 기존의 문서 분류 알고리즘 중 단어 기반 매칭 방법에 대해 알아보고, 그 방법을 실제 HTML 문서에서 어떻게 가공하는지 설명한다. 3장에서는 강화학습에 이용할 기준 페이지 집합을 선택하는 DOPS기법을 제시하고 실험하였고, 4장에서는 DOPS기법을 이용하여 일반적인 검색 방법과 강화학습을 이용한 검색 방법의 성능을 비교하였고, 5장에서는 결론 및 향후연구 과제에 대해 제시하였다.

2. 강화 학습을 이용한 웹 페이지 검색

2.1 강화학습과 웹 검색

강화학습은 동적인 환경 하에서 시행착오를 거쳐 환경으로부터 주어지는 보상을 최대화하기 위한 학습 방법이다. 기본적인 강화 학습 모델에 대하여 살펴보면 [그림 1]과 같다. 학습자가 주어진 환경과 상호 작용을 할 때 상태(state), 행동(action), 보상(reward)이라는 세 가지 기본 틀을 이용한다. 환경은 주로 상태로 표현되며 학습자는 적절한 정책에 따라 행동을 취하게 된다. 이 때, 환경은 학습자에게 행동에 대한 보상을 주게 된다[7]. 따라서 강화 학습이 상태를 행동으로 사상시키는(mapping) 정책인 $\pi: S \rightarrow A$ 를 학습하는 과정이라고 볼 때, 각 상태의 기댓값을 정의할 수 있다.


$$V^*(S) = \sum_0^{\infty} \gamma^t r_t$$

그러면 상태 s 에서 행동 a 를 선택했을 때의 기댓값 $Q^*(s,a)$ 라고 둔다면, 최적(optimal)의 정책은 다음과 같이 나타난다.

$$Q^*(s,a) = R(s,a) + \gamma V^*(T(s,a))$$

가장 높은 보상을 가진 행동을 각 상태에서부터 선택한다면 Q 의 최적의 정책은 다음과 같이 정의된다.

$$\pi^*(s) = \arg \max_a Q^*(s,a)$$



[그림 1] 학습자와 환경간의 상호작용

[Fig. 1] Interaction between Agent and Environment

지금까지 설명한 강화학습을 웹 정보를 검색하는 문제에 적용할 수 있다. 한 웹 페이지가 주어지고 이 페이지에 여러 하이퍼링크가 있을 때, 에이전트는 사용자가 관심 있어 하는 문서를 찾기 위하여 관련 링크를 따라 가면서 정보를 검색하게 된다. 이때 각 웹 페이지들은 상태(state)로 정의하고, 하이퍼링크를 따라가는 것을 행동(action)으로 정의할 수 있다. Q값은 다음 (1)과 (2)를 이용하여 학습하였다.

(1) $W_{Dik} = W_{Dji}$ 인 경우(두 문서를 비교할 때 같은 단어가 나온 경우)

$$\sum_{k,l} \left(\frac{N_{w_{Dji}} - \log(N_{w_{Dj}})}{N_{w_{Dji}}} \right) \cdot |W_{Dik} - W_{Dji}|^2$$

(2) $W_{Dik} \neq W_{Djl}$ 인 경우(두 문서를 비교할 때 다른 단어가 나온 경우)

$$\sum_k^{|D_i|} (W_{Dik})^2 + \sum_l^{|D_j|} (W_{Djl})^2$$

2.2 단어기반 매칭 기법

단어 기반 매칭 방법은 수작업에 의해 분류된 실험 집단(training set) 문서에서의 단어 출현 빈도를 이용하여 새로운 문서를 가장 가능성이 높은 카테고리를 찾아 분류해 주는 방법이다[4].

불용어와 스테밍 처리를 거친 후에 추출된 문서 내의 단어들 가운데에서 문서를 대표할 만한 중요한 핵심어를 추출하는 방법에는 문서간의 단어 출현 빈도의 상관관계를 구하는 TFIDF 방법을 사용한다.

TFIDF란 문서 내의 해당 단어에 대한 출현 빈도(Term Frequency)와 출현하는 문서의 개수(Document Frequency)를 이용하는 것으로, 문서에서의 특정 단어 중요도는 해당 문서 내의 출현 빈도와 비례하고 총 출현 문서의 개수와는 반비례하는 특성을 활용하여 중요 핵심어를 추출한다.

특정 카테고리에서 TFIDF의 weight를 구하는 식은 다음 (3),(4),(5)와 같이 계산된다.

$$(3) \quad tf_{ij} = \frac{freq_{ij}}{\max_k freq_{kj}}$$

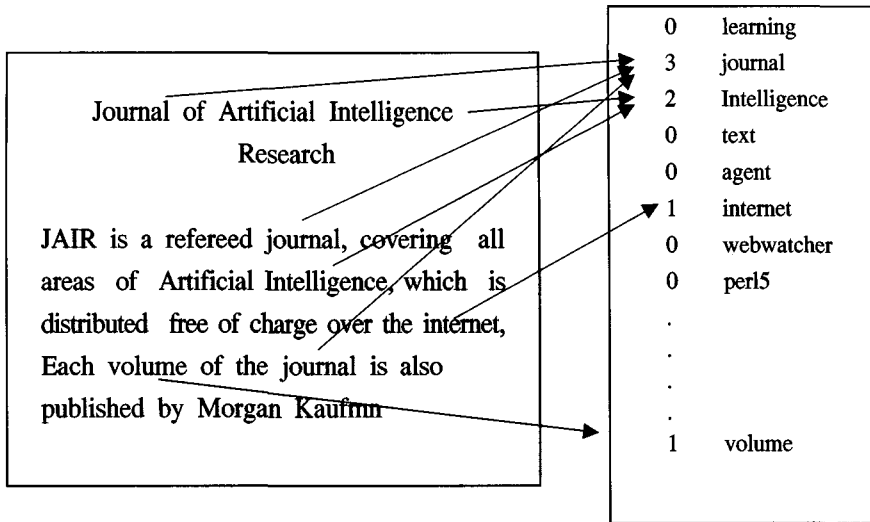
(freq_{ij}:문서 dj안에서 term ki의 빈도수)

$$(4) \quad idf_i = \log \frac{N}{n_i}$$

(N:문서의 전체 개수, n_i:term ki가 있는 문서의 개수)

$$(5) \quad W_{ij} = tf_{ij} \times idf_i$$

관련·비관련 경우들이 같이 섞여 있을 때에는 일반적으로 IDF가 TF보다 더 중요하지만, 본 논문에서는 기계학습 관련 경우들만을 모았고 기준 페이지를 모을 때 주로 conference paper의 abstract 부분만을 가지고 왔다. 그러므로 논문 요약 부분에서 많이 나온 단어는 그만큼 중요도가 크다고 볼 수 있으므로 가중치 계산 시 TF만을 고려하였다.



[그림 2] 빈도수 벡터를 이용한 bag-of-words 방식
 [Fig. 2] Bag-of-words Method using Frequency Vector

본 논문에서는 [그림 2]에서 보듯이 단어의 빈도수를 이용한 bag-of-words 방식을 사용한다. HTML 문서의 텍스트 부분에서 추출되는 키워드 중에는 필요한 정보를 얻어내는 데에 장애가 되는 단어들이 있다.

이러한 단어들을 제거하여 추출되는 키워드를 줄여주는 것이 성능 향상에 도움이 된다. 여기서는 불용어를 제거하고 스테밍 처리를 하였다[3].

까운 페이지를 첫 번째 기준 페이지로 선택하였다. 이후, 기 선택된 페이지들과 가능한 한 직교성(orthogonal)을 갖는 웹 페이지를 동적으로 한 개씩 선택하는 방식을 사용하였다. 이 방법에서는 어느 웹 페이지가 기준 페이지로 선택되면 그와 유사한 페이지들은 선택되지 않게 되는 특징을 가지게 되며, 항상 기 선택된 페이지들과는 비교적 상이한 정보를 갖는 웹 페이지가 동적으로 선택된다는 특징이 있다. 구체적인 알고리즘은 다음과 같다.

3. 동적 기준 페이지 선택 기법(DOPS)

어느 웹 페이지가 특정 키워드와 관련되었는지 그 여부를 판단하려면 해당 영역에 적합한 기준 페이지들을 선택하여 그 중 어느 웹 페이지와 충분히 가까우면 관련 웹 페이지로 판정할 수 있다. 이같이 선택되는 기준 페이지의 수가 가능한 최소이면서도 해당 키워드가 의미하는 영역을 충분히 커버할 수 있어야 한다. 본 논문에서는 DOPS(Dynamic Orthogonal Page selection) 방법을 제시한다.

우선 주어진 N개의 초기 페이지 집합 내의 모든 페이지들의 벡터 평균을 구하고 그 평균에 가장 가

< DOPS Algorithm >

```

PageSet = { Pi | i = 1 to N}
// 이 경우에는 N = 114
P1 = 1st_Reference_Page(PageSet) - ①
/* 첫 번째 기준 페이지를 선택한다.
전체 페이지 집합의 특성을
대표하는 페이지로 선택한다. */
PageSet = PageSet - {P1}
ReferenceSet = {P1}
While(true)
{
    Pi=Most_Orthogonal(ReferenceSet, PageSet) - ②
    
```

```

if (Stopping criterion is met)
    return
ReferenceSet = ReferenceSet + {Pi}
PageSet = PageSet - {Pi}
}
    
```

- ① 1st_Reference_Page(PageSet)
PageSet내의 N개의 페이지의 평균 vector와 가장 거리가 가까운 페이지를 선택한다.
- ② Most_Orthogonal(ReferenceSet, PageSet)
max_distance = 0
for (each page P_i in PageSet)
{
 distance_i \triangleq P_i와 ReferenceSet의 각 element 중 가장 가까운 거리
 if (distance_i > max_distance)
 {
 max_distance = distance_i
 index = i
 }
}
return(P_{index})

초기 확보된 페이지의 수, 즉 PageSet의 크기를 N이라 하고, 최종 선택된 기준페이지의 수를 R이라 하면, 본 알고리즘에서 1st_Reference_Page는 O(N)에 계산되고, Most_Orthogonal은 N개의 각 페이지를 선택된 기준페이지들과 각각 비교하므로 O(NR)에 계산됨을 알 수 있다. 본 알고리즘에서 while 문은 R번 수행되므로, 총 알고리즘 계산시간은 O(NR²)이다. 일반적으로 N은 확보된 관련 웹 페이지의 개수이므로 수백에서 수백만에까지 이를 수 있으나, R은 관련된 기준 문서이므로 매우 작다. 가령 본 실험에서는 R값은 10정도이었다. 따라서, 확보된 웹 문서의 수(N)가 많다면 결국 본 알고리즘은 O(N)에 해당되므로 매우 빠르다 할 수 있다.

본 방법을 전문가와 비교하기 위하여 기계 학습 논문이라는 매우 특화된 영역에 대해 실험하였으며, 해당분야 석사학위 소지자 이상의 전문가와 비교하였다. 실험에서 N = 114를 사용하였는데, 실제 N이 매우 크다면 전문가라도 이 일을 처리하기가 쉽지 않을 것이다.

그 외에도 임의 추출 방식의 웹 페이지 선택 기법도 실험하여 비교하였다.

실험은 기준 페이지의 개수를 1개에서부터 시작하여 일정한 개수만큼씩 늘리면서 거의 변화가 없을 때까지 충분히 실험을 하였다.




그림 3] 기준 페이지 수 vs 인식율

[Fig. 3] #Reference Pages vs. Recognition Rates

[그림 3]에서 ‘무작위선택(random)’은 각 해당 기준 페이지 개수만큼을 무작위로 5번씩 선택하여 실험한 후, 그 결과를 평균한 것이며, DOPS는 제시한 알고리즘을 적용한 결과이다. 그림에서 알 수 있듯이 DOPS의 인식율(recognition rate)이 무작위 선택 시 인식율보다 훨씬 더 좋은 성능을 나타낸다. 그러나 이 두 기법들보다 기계학습 분야의 전문가1,2의 결과가 더 좋게 나타났다. 전문가는 주어진 N개의 페이지를 기준 페이지로 사용될 때의 순위를 매겨, 그 순서에 따라 실험이 이루어 졌다.

본 논문에서 실험 대상으로 모은 초기 웹 페이지들의 집합은 기계 학습 관련 학술대회 논문의 초록(abstract)들이기 때문에 아주 전문적인 영역이었고, 전문가는 선택하는 기준 페이지의 사용 용도를 명확히 알고 있었으므로, 전문가들의 선택이 매우 좋은 결과가 나올 수 있다. 그러나 이와 같이 매우 한정된 수 중에서 전문가가 선택하는 경우에도 전문가는 기준 페이지의 적정 수에 대해 10-20개 수준의 매우 애매한 태도를 취하는 경향이 있음을 주목해야 한다.

본 알고리즘에서 언급되어야 할 또 다른 문제는 알고리즘의 종료 기준(stopping criterion)이다. 언급되었듯이 이는 전문가들도 정하기 어려운 문제이다.

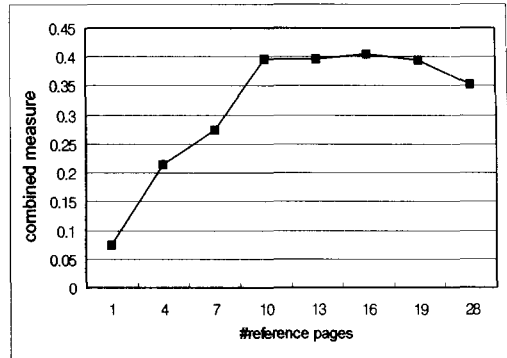
이를 위해 본 논문에서는 0에서 1 사이의 값을 갖도록 정의된 인식율 RR(Recognition Rate)과 역복잡도 IC(Inverse Complexity)의 기하 평균을 합성메저로 이용하였다. 즉 인식율도 높아야 하지만 최종 선택된 페이지의 수가 작아야 한다는 두 가지를 모두 만족하여야 한다. 두 값의 기하평균은 산술 평균이나 p-norm 평균에 비해 두 값 중 한 개라도 좋지 않은 경우 그 평균값을 낮게 평가하는 특성이 있으므로, 두 값 모두를 개선하는지의 여부를 판단하기에 적합하였다. 합성메저 정의식은 다음 (6)과 같다.

$$(6) \quad \frac{2}{\frac{1}{RR} + \frac{1}{IC}}$$

인식율 RR은 DOPS선택 시 인식율을 사용하는데, IC값은 확보된 관련 웹 페이지의 수(N)의 함수가 아니라, 최종 결정된 기준 페이지의 수(R)의 함수이어야 한다. 이를 위해 IC값은 실험적으로 다음과 같이 배정하였다. 즉 현재의 기준 페이지의 수(R₀)보다 기준 페이지 3 개가 더 증가해도 인식율의 증가율이 1%미만일 경우, R₀의 5배의 기준 페이지의 경우 IC가 0점이 되고 기준 페이지의 수가 1개 일 때 IC가 최고점 1.0을 부여하게 하였으며, 그 사이에는 선형으로 IC값을 갖게 배정하였다.

[그림 3]에서 보면 기준 페이지 개수가 10개에서 13개까지의 증가율이 0.6%로 1% 미만이다. 따라서 10개의 5배인 50개의 기준페이지를 사용할 때 IC = 0을 가진다. 기준 페이지 개수가 1일 때 1.0의 값을 가지므로, 기준 페이지 개수가 1씩 증가할 때마다 그 값이 0.02씩 줄어들게 된다.

기하평균을 이용한 합성메저를 적용한 결과는 [그림 4]와 같다. 그림을 살펴보면 기준 페이지의 개수가 10개부터는 이 합성메저가 나타내는 만족도의 변화가 거의 없음을 알 수 있다. 그러므로 최적의 기준 페이지 개수는 더 적은 기준 페이지로 비슷한 만족도를 충족시켜주는 10개 정도가 적당하다. 실제, 전문가들도 최적의 기준 페이지 개수를 선정하는데 어려움을 갖고 있음에 주의해야 한다.



[그림 4] DOPS선택시 합성메저에 의한 만족도

[Fig. 4] Satisfaction Degree by Combined measure under DOPS

4. 웹 검색 실험

본 논문에서 사용된 실험 데이터는 미국 Carnegie Mellon University의 news site와 Washington University의 web site에서 이루어졌다. 실험에서 계산되어지는 Q-value는 하나의 하이퍼링크마다 주어지는데, 그 값의 의미는 웹에서 읽어들이는 페이지와 기준 페이지 집합 중 가장 가까운 페이지와의 거리를 나타낸다. 이 때 문서 분류 조건은, 일치하는 단어가 없는 경우 제외하였고, 단어 일치율이 20% 이하인 경우에도 신뢰도가 떨어진다고 보고 제외시켰다. 그리고 웹 문서에 존재하는 하이퍼링크를 살펴보면, 파일을 가지고 있는 곳을 연결해 주는 하이퍼링크와 끊어진 링크와 시스템 관리를 처리하는 데 사용되는 링크들이 존재하는데 이 실험에서는 제외하였다.

기준 페이지 집합의 선택 기법에 따라 무작위와 DOPS의 인식율의 차이를 앞에서 보았다. 두 선택 기법에 따른 성능의 차이를 비교 실험해 본 결과 다음과 같은 결과를 얻을 수 있었다.

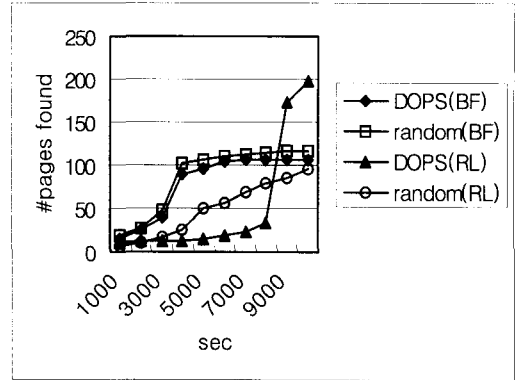
web site의 규모가 작은 Carnegie Mellon University의 news site와 상대적으로 규모가 큰 Washington University 두 경우를 따로 실험한 결과이다.

[그림 5]와 [그림 6]은 Carnegie Mellon University, [그림 7]과 [그림 8]은 Washington University의 시간과 하이퍼링크의 변화에 따른 찾은 문서의 수를 그림으로 나타낸 것이다. 그림에서 「random」은 5개의 무작위 기준 페이지들을 가지고 실험한 후 그 결과의 평균을 나타낸 것이고, 「BF」는 너비우선 방식으로 검색한 것이고, 「RL」은 강화학습 방식으로 검색한 결과이다.

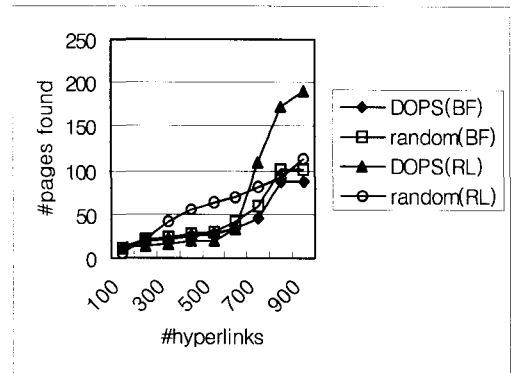
Carnegie Mellon University의 경우, 초기에는 DOPS의 인식율이 좋지 않다가 어느 시점을 기준으로 인식율이 월등히 좋아짐을 알 수 있다. web site의 규모가 작은 Carnegie Mellon University의 news site 결과보다는 규모가 큰 Washington University의 결과인 [그림 7]과 [그림 8]에서 그 차이점이 훨씬 두드러지게 나타나고 있다.

특히 하이퍼링크에 따른 결과에서 뚜렷한 성능 차이를 나타냄으로써, 직교 기준 페이지 집합이 더 적은 하이퍼링크를 거치고도 더 많고 정확하게 우리가 원하는 정보를 찾아준다는 것을 알 수 있다. 너비우선 검색 시 DOPS와 random의 결과가 비슷하게 나타났지만, Washington University의 경우를 보면 너비우선 검색 시에도 random보다는 DOPS방식이 훨씬 더 좋은 결과를 나타내고 있다.

그러므로 특정영역의 문서를 찾고자 할 때에는 너비우선 검색보다 강화학습 검색을 하는 것이 보다 더 짧은 시간에 더 많은 문서를 찾는데 유용하고, 본 논문에서 제시한 동적 기준 페이지 선택 기법을 사용한다면 훨씬 더 나은 결과를 기대할 수 있다.



[그림 5] 시간 비교(CMU자료): random vs. DOPS; 너비우선 vs. 강화학습
[Fig. 5] Time Comparison(CMU): random vs. DOPS; BF vs. RL



[그림 6] 하이퍼링크 수의 비교(CMU 자료): random vs. DOPS; 너비우선 vs. 강화학습
[Fig. 6] Comparison of #hyperlinks(CMU) : random vs. DOPS; BF vs. RL




그림 7] 시간 비교(UW자료): random vs. DOPS;
 너비우선 vs. 강화학습
 [Fig. 7] Time Comparison(UW) :
 random vs. DOPS; BF vs. RL

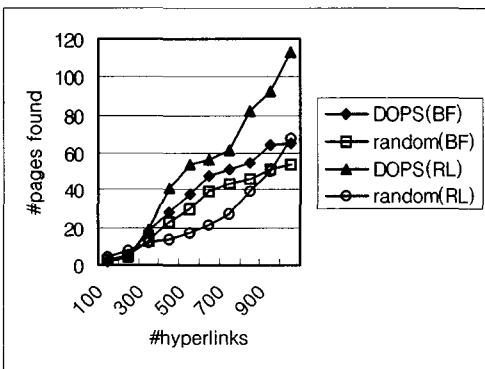


그림 8] 하이퍼링크 수의 비교(UW 자료): random vs.
 DOPS; 너비우선 vs. 강화학습
 [Fig. 8] Comparison of #hyperlinks(UW) :
 random vs. DOPS; BF vs. RL

5. 결론 및 향후 연구

본 논문에서는 특정 키워드 등으로 한정된 영역의 웹 문서 탐색 시 성능 향상을 위한 모델을 제시하고 실험하였다. 특히 초기의 한정된 웹 페이지 집합에서 이 집합을 대표할 웹 페이지들을 찾는 문제를 해결하였다. 제시된 DOPS 방법으로는 관련된 대표적인 기준 웹 페이지들을 찾아줄 뿐 만 아니라 그 적절한 수까지도 제시할 수 있었다. 현재의 실험에서는 기계학습 논문이라는 매우 특화된 전문 분야에 대해 해당 분야의 석사학위 소지 이상의 2명의 전문가와도 비교를 시도하여 비교적 좋은 결과를 얻을 수 있었다. 실제 전문가는 적절한 웹 문서의 수를 결정하는데 어려움이 있었다. 본 실험보다 특화되지 않은 분야, 가령 '전산학 논문' 등의 대표 웹 문서를 찾는 문제 등에 있어 본 방법은, 전문가가 가지는 특정 소 분야에 집착하는 편견을 극복하여 오히려 더 좋은 결과를 보일 수 있을 것으로 사료된다. 또한, 확보된 웹 문서가 매우 커질 경우, 이를 전문가에게 의뢰하여 대표적인 웹 페이지를 찾게 하는 작업은 매우 힘들고 비싼 대가를 치른다는 점을 감안해야 할 것이다.

그리고 웹 탐색 시 강화학습을 적용하도록 하고, DOPS 방법을 이용한 결과, 처리되는 하이퍼링크의 수와 시간적인 측면에서 탐색 성능을 향상시킬 수 있음을 확인하였다.

본 논문에서는 첫 번째 기준 웹 페이지를 전체 초기 페이지 집합의 평균에 가장 가까운 페이지로 선택하였지만, 앞으로는 클러스터링을 구한 후 각 클러스터링을 대표하는 페이지들을 선택함으로써 그 방법의 개선이 가능할 것이다.

또한, 향후에는 DOPS 기법을 웹 페이지가 충분히 모인 후에 주기적으로 적용할 수도 있고, 웹 페이지를 사용자가 실제로 선택(또는 평가)한 결과를 이용하여 기준 페이지 집합을 동적으로 선택할 수도 있을 것이다.

※ 참고 문헌


- [1] David W. Aha, Dennis Kibler, Marc K. Albert, "Instance-Based Learning Algorithm," pp.37-66, Kluwer Academic Publishers, Boston, Manufactured in the Netherlands, 1991.
- [2] R. Dearden, N. Friedman, S. Russell, "Bayesian Q-Learning," Proceedings AAAI-98, Madison, Wisconsin: AAAI Press, 1998.
- [3] Leslie Pack Kaelbling, Michael L. Littman, Andrew W. Moore, "Reinforcement Learning : A Survey," Journal of Artificial Intelligence Research, pp.237-285, 1996.
- [4] Massimo Marchiori, "The Quest for Correct Information on the Web: Hyper Search Engines," In Proceedings of the Sixth International World Wide Web Conference(WWW6), pp 265-276, 1997.
- [5] D. Mladenic and M. Grobelnik, "Word Sequences as Features in Text-learning," pp.145-148, Proc. 7th Electrotechnical and Computer Sc. Conference ERK '98, Ljubljana, Slovenia : IEEE Section 1998.
- [6] C. J. Watkins, P. Dayan, "Q-Learning. Machine Learning," 8(3):279-292, 1992.
- [7] Jason Rennie, Andrew McCallum, "Efficient Web Spidering with Reinforcement Learning," ICML-99 Proceedings of the 16th International Conference on Machine Learning, 1999.
- [8] R. Schoknecht, "Hierarchical Reinforcement Learning with Multi-step actions," 2001.

이 기 철



1977년 서울대학교 전자공
학과 학사
1979년 한국과학원 전산학
석사
1987년 U.of Wisconsin-madison
컴퓨터공학 박사
1980년 1월~1982년7월 국
방과학연구소 연구원
1989년 3월 ~현재 홍익대학
교 컴퓨터공학과 교수

이 선 애



1990년 8월 영남대학교 통
계학과 졸업(이학사)
1990년 11월 ~ 1996년 10
월 (주)대웅제약 경영정
보팀(전산실) 근무
2002년 2월 홍익대학교 대
학원 컴퓨터공학과 졸업
(공학석사)
관심분야 : 웹마이닝, 데이
터마이닝, 기계학습