

웹 정보 검색 환경에서의 사용자 기호 학습

서영우¹, 장병탁
서울대학교 컴퓨터공학과

Learning User Preferences in Web Information Retrieval

School of Computer Engineering and Science, Seoul National University

요 약

본 논문은 웹 기반의 정보 여과 시스템인 WAIR를 이용하여 사용자의 기호를 학습하는 방법을 설명한다. 제시된 방법은 여과된 문서들에 대한 사용자의 반응을 관찰하여 각 개인 사용자의 프로파일을 학습한다. 사용자의 기호를 가장 잘 표현하는 단어들을 찾는데 강화 학습을 사용하였다. 기존의 방법은 사용자의 명시적인 적합성 평가(relevance feedback)를 이용하여 검색 또는 여과 성능을 향상시킨 반면 제시된 방법은 사용자의 기호를 묵시적 적합성 평가를 통해 학습한다. 여과된 문서에 대한 사용자의 행동을 통해 사용자의 명시적 평가를 추측하는 것이다. 약 7,000 여개의 HTML 문서에 대해 7명의 사용자가 약 4주 동안 실제 웹을 대상으로 웹 문서 여과 실험을 실시하였다. 제시된 방법은 기존의 적합성 평가를 이용한 정보 여과 방법보다 각 개인에게 보다 적절한 정보를 제시하였다.

1. 개 요

최근 정보 통신과 컴퓨터 관련 기술의 발전으로 이용 가능한 전자 정보량이 폭발적으로 증가하고 있다. 정보의 양이 증가할수록 특정 정보 공간에서 정보 요구에 보다 적절한 정보를 찾는 요구 역시 비례적으로 증가하고 있다. 특히, 접근이 용이한 웹과 같은 대규모의 정보 집합에서 각 개인 사용자가 원하는 정보를 찾아 주거나 여과시켜주는 정보 검색과 정보 여과는 현재와 같은 정보 과부하 현상아래에서 해결해야 할 중요한 문제이다 [1].

현재, 웹 문서정보에 접근하는 방법은 AltaVista, Yahoo!, Excite 등과 같은 웹 검색엔진을 이용하는 방법과 자신이 알고 있는 URL로부터 하이퍼 링크를 계속적으로 따라 가는 방법으로 크게 분류할 수 있다. 그러나, 첫 번째의 방법은 사용자의 부적절한 검색어 사용 또는 검색엔진의 범용성을 땀 색인 방법으로 인하여 검색결과 대부분이 사용자의 정보 요구에 적합하지 않다는 단점이 있고, 두 번째의 경우는 적합한 정보를 찾는데 걸리는 비용이 너무 많이 든다는 점과 여러 단계의 계층적인 형태의 하이퍼 링크 구조의 복잡성으로 인하여 처음 자신이 찾고자 했던 정보요구를 잊어버리고 다른 정보에 관심을 빼앗기는 등의 단점이 있다.

본 논문은 이러한 단점을 해결하는 방법의 하나로 강화학습(reinforcement learning)을 이용하여 사용자의 기호를 학습하고 이를 통한 웹 문서 여과하는 방법을 제시한다. WAIR(Web Agents for Information Retrieval)는 본 논문에서 제시한 내용을 구현한 시스템으로 여과한 문서들에 대한 사용자의 반응을 관찰하여 사용자의 기호를 학습하고 학습된 결과

를 통하여 보다 사용자의 기호에 적합한 문서를 검색하여 여과한다. 대부분의 경우 사용자는 초기에 하나의 질의어로 정확하게 자신의 정보 요구(information needs)를 표현하지 못한다. 그러나, 사용자에게 특정 문서를 제시하면 그 문서가 자신의 정보 요구와 적합한지 아닌지는 쉽게 선별할 수 있다(user relevance feedback). 사용자가 선별한 문서들을 이용하여 질의어 내의 각 단어들의 중요도(weight) 조절, 새로운 단어의 첨가, 불필요한 단어제거 등을 통하여 초기의 질의어를 수정(query modification)하면 검색의 성능이 우수해지지만[4], 사용자가 모든 검색결과에 대해서 일일이 평가를 내리는 데 한 비용이 크다. 본 논문에서는 여과된 문서들에 대해서 보이는 사용자들의 행동을 관찰하여 적합성 평가를 획득하고 질의어를 확장할 때 강화 학습을 이용한다.

본 논문은 다음과 같이 구성되어 있다.

2절은 WAIR 시스템을 이용한 웹 문서 여과와 학습과정을 살펴보고, 3절에서는 실제 정보 여과 실험을 통해 제시된 방법의 성능을 평가한다. 그리고 마지막으로 실험의 결과와 향후 연구에 대해서 토론한다.

2. 웹 문서 여과 과정

WAIR가 사용자로부터 질의어를 입력받아서 HTML 문서들을 여과하는 전체 과정은 그림 1과 같다. 그림 1의 과정 1에서 사용자의 프로파일(P)은 사용자가 입력한 하나 이상의 질의어로 구성되는데, 질

1. Get a topic $Topic_p$ from the user.
2. Generate the set of candidate HTML documents.
 - 2.1 Generate the number of U URLs using the existing search engines.
 - 2.2 Repeat the following steps until $i \leq U$.
 - Get the i th HTML document(D_i).
 - Preprocess the document.
 - Estimate the value of relevance.
 - If there is a profile, it is estimated with profile;
 - otherwise with initial topic $Topic_p$.
 - $i = i + 1$.
3. Filter the set of candidate HTML set and present the result.
4. Get the feedback from the user.
5. Learn user profile.
6. Select the next retrieval points from the documents evaluated as relevant.
7. If user inputs a new topic, then goto 1, otherwise goto 2.

그림 1: WAIR 시스템의 전체 문서 여과 과정

의어(topic)는 초기 질의어(Q_0 , name)와 질의어에 대한 사용자의 기호를 표현하는 내용(contents)로 구성된다. 각 질의어의 내용은 여과 과정이 진행되는 동안 수정되면서 사용자의 의견을 반영하게 된다. 사용자의 적합성 평가는 단어들로 표현된 벡터 공간에서 사용자의 정보 요구를 정확하게 표현해 줄 수 있는 지점을 찾기 위해 질의어 벡터의 크기와 각도를 조절하는 것으로 볼 수 있다.

전처리 과정을 거친 후 각 HTML 문서(D_i)는 사용자의 질의어(Q)에 대해 내용(contents)에 해당 단어가 있으면 다음과 같은 과정을 통해 유사도(similarity)가 평가되어 유사도값(RV)순으로 사용자에게 제시된다.

$$RV(D_i) = \sum_{j=1}^n t_{ij} \times tw_{pk} \quad (1)$$

if $Q \subset P$ and $term_{ij} \in contents_p$

벡터 공간 모델[2]에서 사용자 적합성 평가를 이용하여 초기 질의어를 확장하는 방법들의 기본적인 형태는 다음의 Rocchio 알고리즘이다 [3].

$$Q = Q_0 + \frac{1}{n_1} \sum_{i=1}^{n_1} R_i - \frac{1}{n_2} \sum_{i=1}^{n_2} S_i$$

위 식에서,

Q_0 : 초기 질의문 벡터

R_i : Q 에 적합한 문서집합의 i 번째 문서

S_i : Q 에 적합하지 않은 문서집합의 i 번째 문서

초기에 사용자가 입력한 질의어(Q_0)에 대한 결과 중 적합한 n_1 개의 문서들에서 단어들은 초기 질의어 내에 포함하고 적합하지 않은 n_2 개의 문서들에 포함된 단어들은 제거하여 Q 로 수정한다. Ide는 질의어 확장의 대상을 가장 적합하지 않은 문서 하나만으로 축소하여 Rocchio 알고리즘을 확장하였다 [2]. WAIR는 사용자의 적합성 평가를 직접 반영하여 Q 내의 단어들의 중요도를 수정한다.

$$Q = Q_0 + \sum_{i=1}^m \beta r_i R_i \quad (2)$$

위 식에서,

r_i : 여과된 i 번째 문서에 대한 사용자의 적합성 평가

식 (2)에서 β 는 학습의 속도를 조절하는 상수이다. 본 논문에서는 앞 절에서 언급한 바와 같이 초기 질의어 확장에 강화학습을 이용한다. 강화학습은 목표 지향적(goal-directed) 학습방법으로 시도와 오류(trial-and-error), 지연된 보상(delayed reward), 그리고 주어진 환경과의 상호작용을 통하여 학습(learning from interaction)하

는 특성을 가지고 있다[6]. 강화 학습자는 시각 t 의 주어진 상태(state) s_t 에 학습자 자신의 정책(policy)에 따라 어떤 행동(action) a_t 를 행하면 자신이 위치한 환경으로부터 스칼라 값의 보상 신호 r_t 를 받는다. 정책이란 주어진 시각에 학습자가 취할 수 있는 행동 집합에서 특정 행동을 선택하게 되는 기준이다. 강화 학습자의 목적은 장기간 환경으로부터 받는 보상 예상치를 최대화시키는 것이다.

WAIR에서의 목적은 여과된 문서에 대하여 모두 적합하다는 사용자의 평가를 받는 것이다. WAIR의 행동은 초기 질의어를 확장할 때 단어 선택방법으로 정의되며 ϵ -greedy 방법을 사용한다. 특정 질의어(topic)의 내용(contents)를 구성하는 단어의 수를 m 개라 할 때 $m - \epsilon$ 개는 가장 높은 중요도 값을 갖는 단어를, ϵ 개는 무작위로 선택한다. $m - \epsilon$ 개의 단어는 현재까지 학습한 지식을 최대한 이용하는 활용(exploitation)이며 ϵ 개의 단어는 현재는 별로 가치가 없지만 장기적인 관점에서 보았을 때 중요하리라고 추측되는 선택하는 탐구(exploration)이다. Rocchio와 Ide가 제안한 기존의 알고리즘은 질의어를 확장할 때 중요도 값이 높은 단어나 가장 일반적인 단어들을 선택하므로 정보 요구를 잘 표현하는 단어를 찾는 것이 상당히 느릴 수 있다. 본 논문에서 제시한 방법은 강화 학습의 수렴조건을 만족하므로 보다 빨리 사용자의 프로파일을 학습할 수 있다[6].

식 (1)을 통해 여과된 문서들은 사용자로부터 적합성 평가를 받게 된다. 적합성 평가는 사용자가 각 문서에 대해서 일정 범위의 수치를 직접 주는 명시적인 평가 형태($E(t)$)와 문서에 대해 보이는 사용자의 행동으로 명시적인 평가를 대체할 수 있는 묵시적인 평가 형태($I(t)$)가 있다. 사용자로부터 명시적으로 적합성 평가를 받아서 이후 여과 과정에 적용하면 성능은 좋아 질 수 있지만 사용자의 비용이 커지고 비용이 커짐에 따라 정확한 평가를 획득하기 힘들다.

WAIR에서 명시적인 평가는 적합하다(relevant), 그저 그렇다(neutral), 그리고 적합하지 않다(irrelevant)로 나누어서 평가를 받는다. 명시적인 평가를 대체하기 위해서 여과된 문서를 읽는 시간(rt), 북마크를 한다(bm), 문서내의 하이퍼 링크를 따라 간다(fl) 등의 묵시적 평가요소를 고려한다.

$$I_{d,i,t} = \sum_{v \in V} w_v f_v(t) \quad (3)$$

$$V = \{rt, bm, fl\}$$

식 (3)에서 명시적 평가 요소(V)의 성분들이 참여하는 비율(w_v)는 여과된 문서의 적합성과 사용자 행동간의 관계를 실험하여 결정하였다. 주어진 시각 t 에 여과된 각 문서의 적합성 평가는 아래와 같이 측정할 수 있다.

$$r_{d,i,t} = \alpha E(t) + (1 - \alpha) I(t) \quad (4)$$

위 식에서, $0 \leq E(t) \leq 1$, $0 \leq I(t) \leq 1$

식 (4)에서 α 는 명시적인 평가와 묵시적인 평가의 참여 비율을 조절하는 상수이다. WAIR가 선택한 단어들로 유사성을 평가하여 여과한 문서들에 대한 사용자의 보상과 단어들의 가치치 변화를 계산하면 현재 질의어(topic)에 대한 내용(contents)이 사용자의 초기 정보요구를 얼마나 잘 표현하는지 알 수 있다.

$$CV_{b,t} = \frac{1}{U} \sum_{d_i \in U} r_{d,i,t} + \gamma CV_{b,t+1}, \quad (5)$$

위 식에서, $0 \leq \gamma \leq 1$

$$CV_{b,t+1} = \sum_{k=m}^m \Delta tw_{pk} \\ \Delta tw_{pk} = tw_{pk}(t) - tw_{pk}(t-1)$$

위 식에서 γ 는 예상되는 미래의 보상이 현재 값에 반영되는 비율을 조절하는 상수이다.

3. 정보 여과 실험

제시된 방법을 이용하여 여러 가지 실험을 실행하였다. 첫 번째 실험은 사용자의 행동과 여과된 문서의 적합성간의 연관성을 확인하는 것과 제시된 방법과 기존의 방법간의 성능 비교가 목적이다. 이 실험에서는 실험자 7명의 14개의 질의어(topic)에 대해서 약 5,600개의

HTML문서를 여과시켜 제시하였다. 각 사용자들은 그림 1의 WAIR 실험환경을 통해 실험을 하였다. 그림 1에서 A는 여과된 결과를 북마크하는 부분이고 B는 여과된 HTML문서를 보는 브라우저, C는 여과 결과를 보여주는 창이다.

표 1은 사용자가 평가한 적합성의 단계와 실험 환경에서 보여준 행동과의 관계에 대한 통계치이다. 이 실험에서 각 실험자는 하나의 질의어에 대해 최소 300개의 HTML 문서를 평가하였다. 표 1의 수치 중 북마크가 세 개의 목시적 평가 요소에서는 가장 작은 비율을 차지하고 있지만 특정 요소에 대해 적합한 것과 적합하지 않은 문서의 비율에서 가장 의미 있는 수치를 보이고 있다. 표 1의 통계치를 기준으로 목시적 적합성 평가 요소의 비율을 북마크(bm)는 0.6, 읽는 시간(rt)은 0.3 링크 추척(fl)은 0.1로 설정하고 1,400개의 문서에 대하여 목시적인 평가를 이용한 문서 여과 실험을 수행하였다(그림 2). 그림 1의 e-match는 질의어 확장을 하지 않고 검색된 각 문서가 초기 질의어를 포함하는지 여부만을 고려한 방법이다.

4. 결 론

본 논문에서는 사용자와의 목시적 상호작용을 통해 초기 질의어 수정에 필요한 정보를 획득하는 새로운 적합성 평가 방법을 제시하였다. 실험을 통해 기존의 적합성 평가 보다 사용자에게 적합한 문서를 여과하는 것과 목시적인 적합성 평가 방법을 통해 효과적으로 사용자의 기호에 적응하는 것을 보였다. 사용자에게 적응하는 속도의 관점에서 보았을 때 기존의 방법보다 빨랐다. 실험결과를 통해 사용자의 행동을 통한 사용자의 기호 학습방법을 통한 개인화된(personalized) 정보 여과 시스템의 성능을 향상시킬 수 있다는 결론을 내렸다.

그러나, 비교적 성공적인 실험 결과가 제한된 실험 환경에서 기인한 아래의 이유에 의한 것이 아닌가라는 문제를 고려해야 할 것 같다. 첫 번째 이유는 실험자들이 사용한 질의어들이 대부분 구체적인 정의와 사례들을 가지고 있는 전문 용어들이었기 때문에 WWW의 특징을 제대로 표현하지 못했다는 것이다. 두 번째의 이유는 실험이 오랜 기간 계속되지 않았다는 점이다. 사용자의 기호에 대한 보다 오래 기간동안의 실험은 현재 진행 중에 있다.

마지막으로 좀 더 실용적인 측면의 정보 검색과 정보 여과는 정보 요구에 대한 결과를 반환해 주는 시간이 상당히 중요한 요소이다. 그러나, 본 논문에서는 시간을 고려하지 않았으며 향후 연구과제로 고려하고 있다.

감사의 글: 본 연구는 정보통신부가 시행하고 있는 대학 기초 연구기술 지원사업에 의해 지원되었으며 초고속정보통신 응용기술개발사업에 의해 일부 지원되었음.

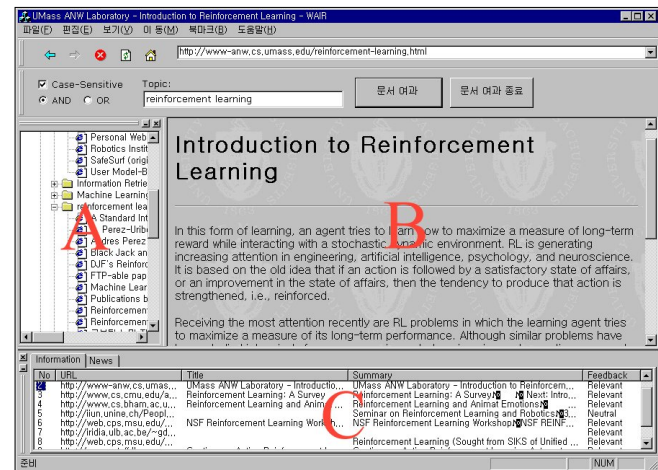


그림 2: WAIR의 실험 환경.

| 적합성 평가 | Relevant | Neutral | Irrelevant | Total |
|--------------|----------------------|---------------------|-----------------|------------|
| Bookmark | 922(61%) | 575(38%) | 15(1%) | 1,512(27%) |
| Follow up | 3,168(69%) | 1,194(26%) | 230(5%) | 4,592(82%) |
| Reading time | $32 \geq rt \geq 22$ | $22 \geq rt \geq 7$ | $7 \geq rt > 0$ | 5,376(96%) |
| | 3,118(58%) | 1,344(25%) | 914(17%) | |

표 1: 사용자의 행동과 문서의 적합성 간의 관계 실험.

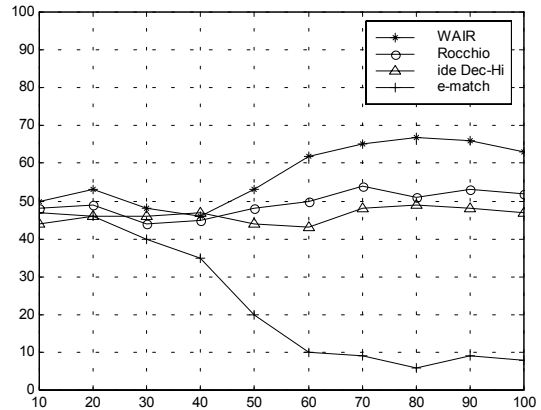


그림 3: 기존의 방법과 제시된 방법간의 평균 적합성 평가 비교, x축: 여과된 HTML 문서의 수, y축: 명시적인 적합성 평가의 평균




그림 4: 목시적인 평가를 이용한 문서 여과의 평균 적합성

참고문헌

- [1] Nicholas J. Belkin and W. Bruce Croft, Information filtering and information retrieval: two sides of the same coin?, *Communications of the ACM*, Vol. 35, No. 12, pp.29-38, 1992.
- [2] G. Salton, *Automatic Text Processing*, Addison-Wesley, 1989.
- [3] Rocchio, J. J, Relevance feedback in information retrieval, *The SMART Retrieval System*, pp.313-323, Prentice Hall, 1971.
- [4] Gerard Salton and Chris Buckley, Improving retrieval performance by relevance feedback, *Journal of American Society for Information Science* 41, pp.288-297, 1990.
- [5] Richard S. Sutton and Andrew G. Barto, *Reinforcement Learning: An Introduction*, MIT Press, 1998.
- [6] Tom M. Mitchell, *Machine Learning*, McGraw-Hill Com. Inc., 1997.