

Hop 제약조건이 고려된 최적화 웹정보검색*

이우기**[†] · 김기백*** · 이화기****

Optimized Structures with Hop Constraints for Web Information Retrieval*

Wookey Lee** · Kibaek Kim*** · HwaKi Lee****

■ Abstract ■

The explosively growing attractiveness of the Web is commencing significant demands for a structuring analysis on various web objects. The larger the substantial number of web objects are available, the more difficult for the clients (i.e. common web users and web robots) and the servers (i.e. Web search engine) to retrieve what they really want. We have in mind focusing on the structure of web objects by introducing optimization models for more convenient and effective information retrieval. For this purpose, we represent web objects and hyperlinks as a directed graph from which the optimal structures are derived in terms of rooted directed spanning trees and Top- k trees. Computational experiments are executed for synthetic data as well as for real web sites' domains so that the Lagrangian Relaxation approaches have exploited the Top- k trees and Hop constraint resolutions. In the experiments, our methods outperformed the conventional approaches so that the complex web graph can successfully be converted into optimal-structured ones within a reasonable amount of computation time.

Keyword : Web Structuring, Binary Integer Linear Programming Model, Top-K Retrieval, Hop Constraints, Lagrangian Relaxation

논문접수일 : 2007년 10월 06일 논문제재확정일 : 2008년 11월 13일
논문수정일(1차 : 2008년 06월 10일)

* 본 연구는 지식경제부 및 정보통신연구진흥원의 대학 IT연구센터 육성 · 지원사업(IITA-2008-C1090-0801-0031)의 연구결과로 수행되었음.

** 인하대학교 산업공학과 교수

*** Texas A&M 석사과정

**** 인하대학교 산업공학과 교수

† 교신저자

적으로 찾는 알고리즘이다. 권위 웹 페이지는 질의 하는 주제에 대해 좋은 내용을 담고 있는 페이지들을 의미하며, 좋은 연결고리 페이지들로부터 링크가 많이 걸리게 된다. 역으로 우수한 권위 페이지들과 링크를 많이 가진 페이지들이 또한 좋은 연결고리 페이지들이 된다. 이는 사회연결망(Social Network) 혹은 공동체망(community networks)관련연구의 기초가 되었으며[18, 24, 28], 일명 상호강화 관계성(mutually reinforcing relationships)라고 부르는 요소의 추출에 활용되고[18], 또한 기술망(technical networks), 혹은 논문의 인용정도 (scientific and patent citations) 등에 사용되고 있다. 그러나 원래의 논문자체에서 사용한 정통적 문제 즉, 웹 정보의 검색에는 HITS가 뜻밖에도 적용되지 않고 있다. 그 이유는 첫째, 동일한 노드를 권위 페이지와 연결고리 페이지로 분리해석한 점에서 비현실성이 노정된 것과 둘째, 전이행렬(transition matrix)의 특성에 있어서 복수 최대 특성값 (Dominant Eigenvalues)의 경우 등 알고리즘의 수렴성 및 안정성이 문제가 있기 때문이다.

한편 페이지랭크(PageRank) 알고리즘[21, 31]은 상기 약점들이 제거되어 현재 정보검색 및 검색엔진에 있어서 가장 폭넓게 적용되고 있다. 그러나 페이지랭크 역시 나가는 아크의 가중치는 모두 동일하다는 가정이 비현실적이다. 따라서 받는 노드와의 관련성에 따라 차등되는 아크 페이지랭크로의 변형이 필요하다. 따라서 본 연구에서는 실험부분에서는 페이지랭크 알고리즘뿐만 아니라 이를 보완한 가중치를 적용해보았다.

현재 웹에서 광범위하게 무시되고 있는 특성의 하나는 계층적 구조이다. 이는 도메인 이름체계 (Domain Name System)와 웹 페이지들이 각 웹 사이트 내부에서 물리적으로 존재하는 방식이 루트노드로부터 개별 디렉터리 그리고 하위 디렉터리들 그리고 개별 웹 페이지들로 만들어지는 이러한 구조가 웹 검색에 직접적으로 적용된 경우가 적다[36]. Eiron et al.[11]의 경우 웹 그래프 모델에서 링크구조를 통합하여 명백히 계층적 구조로 변형하는 방

법을 제안하였고, 그 연구는 해당 조직의 구성과 관련 웹 사이트의 구조를 결합하는 방식이다.

한편 페이지 방문횟수(Page Popularity) 즉, 웹 로그 정보에 따라 웹 페이지의 배치를 재구성하는 시도도 있으나[13, 17], 이는 변화가 많은 웹의 환경에서는 구조가 지나치게 자주 바뀌거나 단기적인 방문기록 혹은 악의적인 방문공격(DoS : Denial of Service)에 취약할 우려가 있다. 본 연구에서는 웹 로그를 사용하지 않고 웹 페이지 및 웹 아크에 대한 전통적인 가중치들을 사용하여 문제의 일반성을 해치지 않도록 하였다.

그 밖에도 [20, 21] 및 [7]의 일반화된 웹 로봇을 포함한 웹 검색 방식에 대한 연구들도 연관성이 있다. 특히 [20]의 경우 웹 로봇의 검색 스케줄 정책에 대해 연구하였는데, 그들은 약 18만 개의 웹 페이지에 대해 다양한 웹 로봇 전략 즉, 넓이우선 정책, 백링크 숫자우선, 페이지랭크 우선 등을 적용하였다. 그 결과 높은 페이지랭크 우선 전략 다음으로 넓이우선 정책이 좋은 내용을 보였다는 점을 확인한 것은 의미 있는 발견이었으나, 단 하나의 도메인에 적용한 결과로 일반화하기는 어렵다. 다음으로 Najork와 Wiener의 경우[27] 3억 개 이상의 페이지에 대해 넓이우선 전략을 적용하였고, 결과적으로 의미 있는 페이지들을 가지고 오는 효과를 입증하였다. 다른 전략들과 비교하지는 않았으며, 깊은 데 위치한 페이지들의 중요성은 확인하지 못한 약점이 있다. Abiteboul 등의 연구[1]에서는 OPIC라는 알고리즘을 제시하여 각 페이지가 초기 ‘금액’을 각 노드에 한 번에 나누어주는 방식으로 가중치를 구했다. 이는 페이지랭크와 비슷한데 한 번의 연산으로 계산하기 때문에 아주 효율적으로 가중치를 구할 수 있으며, 10만 개의 페이지에 대해 수행해보았다. 그러나 이 역시 다른 전략들과 비교하지 않았다. 본 연구에서는 다른 전략들과 비교하였으며, 더 나아가 제안하는 웹 구조화 정보 즉, 메타정보는 일반사용자 및 웹 로봇에게 사이트맵으로 제공될 수 있다는 장점이 있다.

다음으로 웹의 구조화를 위한 노력은 웹사이트

설계에도 적용되고 있다. 사용자의 접근 패턴을 분석하여 사이트 구성과 인터페이스를 자동화된 방법으로 개선하는 적응적 웹 사이트를 제안한 접근법도 있다[32]. 이들은 사용자와의 상호작용에 근거하여 사이트 구조를 개선시키는 것을 목표로, 기존 구조를 건드리지 않고 링크를 추가하되, 기존 링크는 제거하지 않는 비파괴적인 방식의 변형을 시도하였다. 이 경우 알고리즘의 성능 분석에 그치고, 클러스터링 등의 효과가 제시되지 않는 단점이 있다. Botafodo et al[4]의 연구에서는 웹 사이트를 설계할 당시 설계자가 의도했던 계층 구조를 찾아내고, 하이퍼텍스트 구조의 또 다른 특징을 설계자에게 보여 줌으로써, 사용자 인터페이스와 웹 사이트 구조를 개선하고자 하였다. Fu 등의 연구[12]는 페이지 클러스터를 생성하지 않고, 사용 패턴의 진화에 따라 웹사이트 구조와 구성이 변화하도록 허용하였다. 제안한 방법론의 유효성을 증명하기 위하여, 정확하게 분류된 페이지 비율로서 정확도 측정을 하였다. 이러한 접근법은 다소 지나친 재구성화 방식으로서, 실제로 서버 입장에서 볼 때 실용적인 방법론이라고 볼 수 없으며, 사용자 입장은 더욱 고려되지 않았다. 웹사이트 및 페이지 분석과 관련해서는 공영기관인 W3C에서 수행하는 유효성검사(validator.w3c.org) 및 링크구조분석 서비스가 있는데[39, 40] 이는 태그의 중첩성 분석 등에 지나지 않는다.

적응적 웹사이트 분석을 위해 선형계획법을 적용한 연구[24]가 있는데, 여기서는 목적 함수로 모든 링크들의 빈도수합계를 최대화하는 것을 설정하였다. 링크 빈도수는 동시 발생 빈도수로 표현된다. 제약 조건으로는 노드의 외부 링크수(정보 부담)와 홈페이지로부터 각 페이지로의 최단 경로 길이 즉, 탐색 길이에 대한 제한을 두었다. 그리고 성능 효율을 개선하고자 2국면 허리스틱을 개발하였다. 활용도가 낮은 링크 제거를 통한 웹 사이트 재구조화를 수행하였고, 적응적 웹 사이트는 사용자 특성에 따라 개별적으로 혹은 전체적으로 적용하는 웹사이트를 구성하자는 것이다. 이 연구에서의 큰 약점은 사

용자 방문빈도를 “선형 독립”으로 적용한데 있다. 예컨대, 웹 페이지⁷에 대한 방문 경로가 $0 \rightarrow 2 \rightarrow 7$ 일 경우, $2 \rightarrow 7$ 의 방문빈도(Hit ratio) 혹은 머문 시간(duration time)은 그에 선행하는 $0 \rightarrow 2$ 에 독립적이라고 보았다. 그리고 이를 바탕으로 0-1정수 선형계획법을 적용한 것은 당연히 부적절하다고 볼 수 밖에 없다. 따라서 본 연구에서는 웹 로그 등에서 얻어지는 사용자 방문빈도로 접근하지 않고, 일반적인 키워드 정보를 바탕으로 수행했다. Lee[36] 및 Lee and Lim[37] 연구는 선형계획법을 정보검색에 적용한 최초의 시도였다. 그러나 여기서는 일반적 최적트리를 적용한 의의는 있으나, Hop제약조건이나 Top- k 등에 대해 고려하지 않았다. 이점에서 흡 제약이 있는 최소합 아보레스نس(HCMA : Hop Constrained Min-Sum Arborescence) 접근법은 주목할 만하다. 원래 이 문제는 네트워크 설계와 라우팅, 스케줄링과 같은 분야에서 자주 다루어지는 것으로, 다양한 접근법이 있으나 웹을 대상으로 한 연구는 없었다. 기술적 관점에서 Gouveia[14]는 HCMA 문제를 정수계획법 문제로 모델링하고 이를 해결하기 위해서 라그랑지안 기반의 발견적 방법을 제안하였다. Kawatra[22]의 연구에서는 HCMA 문제를 풀기 위해 라그랑지안 완화법과 서브 그리디언트 최적화(Sub-gradient Optimization), 가지교환 허리스틱(Branch Exchange Heuristic)을 이용하는 방법을 제안하였다. 이들 역시 웹 환경에 적용된 적이 없으며, 또한 아크나 페이지가 변화되는 일반적인 웹 검색 및 웹 구조화와는 거리가 멀다.

3. 최적화 모델

3.1 가중치의 계산

가중치(Weight)란 웹 객체 즉, 사용자의 질의(query) 및 그 대상이 되는 웹 페이지 혹은 아크 이들 사이의 유사도(Similarity) 혹은 거리(Distance)를 의미한다. 가중치는 글로벌 가중치와 로컬 가중치로 분류될 수 있는데, 이들은 상호 독립적이다.

- 5) 스텝사이즈와 서브 그라디언트 값을 이용하여, 새로운 라그랑지안 송수들을 구한다.

$$\begin{aligned}\lambda_t &= \max(\lambda_t + T1 \times G1_t, 0), \\ \mu_{ijt} &= \max(\mu_{ijt} + T2 \times G2_{ijt}, 0), \\ \nu_{it} &= \max(\nu_{it} + T3 \times G3_{it}, 0)\end{aligned}$$

새로운 라그랑지안 송수를 이용하여 (2)의 과정에서부터 반복하여 계산한다. 이 알고리즘의 종료조건은 반복연산의 수가 600회 이상이 되면 종료한다.

4.3 라그랑지안 휴리스틱

본 연구에서는, 라그랑지안 완화모델을 이용해서 해를 구하기 위해 최적해의 하한 값과 상한 값을 구한 후 서브 그라디언트 최적화 알고리듬을 사용하였다. 그러나 앞에서 서브 그라디언트 최적화 알고리듬을 이용하여 구한 하한 값은 본래 문제에 대해 불능해를 갖기 때문에, 이 불능해를 본래 문제에 대해 가능해를 찾아야 한다. 이를 위하여 본 연구에서는 휴리스틱기법을 이용하였다.

이 연구에서 적용한 휴리스틱을 위해 다음과 같은 가정을 하였다.

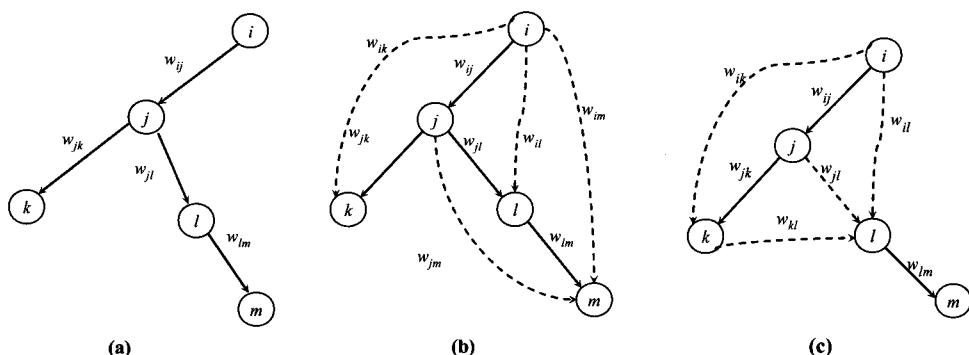
1. 앞서 구한 라그랑지안 완화법의 가능해, 즉 본래 문제에 대해 불능해는 3.3절의 제약조건 (3)을 만족시키지 못한다.

2. 웹 사이트의 트리구조에서 경로제약에 위반되는 가지를 찾아 경로제약을 넘어서는 가지를 끊은 후, 다른 노드에 연결함으로써 본래 문제에 대해 좋은 가능해를 구할 수 있다.

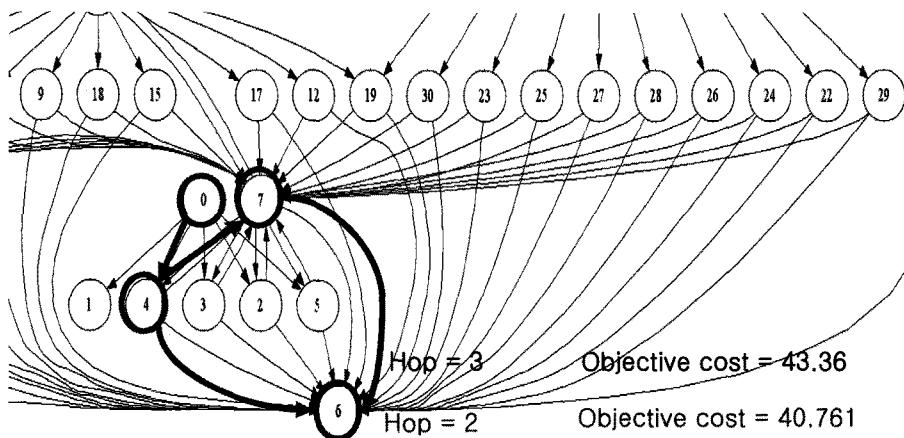
이를 위해 우리는 위의 가정을 만족시키는 알고리듬을 개발하여 사용하였다. 이 알고리듬의 절차는 다음과 같다.

[알고리듬]

- (1) 모든 페이지에서부터 경로를 역으로 추적하여 회로를 탐색한 후 회로가 있으면, 회로의 경로 중 하나를 삭제한다. 없다면, 시작페이지에 도달한다.
- (2) 회로로부터 삭제된 경로가 향하던 페이지로의 경로를 생성한다. 모든 페이지에 대해 수행이 끝나면 트리구조가 완성된다.
- (3) 웹사이트 트리구조의 종점페이지를 찾은 후, 모든 종점페이지에서부터 시작페이지까지의 경로의 수를 계산하여, 경로제약조건을 위반하는지 판단한다. 없으면 종료한다.
- (4) 경로제약조건을 위반하는 종점페이지에 대하여, 시작페이지까지의 총 경로의 수가 ($Hop\text{수} * 2$)이하면 종점페이지에서 (총 경로의 수 - $Hop\text{수}$)번째 되는 경로를 삭제하고, 총 경로의 수가 ($Hop\text{수} * 2$)이상이면 종점페이지에서 ($Hop\text{수}$)번째의 경로를 삭제한다.



[그림 8] Hop을 고려한 Top-k 노드탐색



[그림 10] 노드 6번에 대한 변경과정 및 최적해의 변화내역

색엔진의 입장에서는 사용자가 접근해야 할 대상 웹 페이지들을 구조화하여 표현할 수 있는 장점이 있다. 본 연구에서는 이 모델을 복잡하게 하는 제약조건의 수를 줄이고, 계산에 있어 부담을 주는 제약조건들을 라그랑지안 완화법을 통해 완화함으로써 사용자에게 편의를 제공함과 동시에 근접해를 통한 최적해의 손실정도를 구할 수 있음을 제시하였다. 이러한 모델을 기반으로 가상노드 및 실제 웹에 적용하였으며, 제약조건을 완화한 해를 구하여 최적해의 유지와 제약식의 완화효과에 대한 비용분석을 하여 그 실제성을 입증하였다.

향후 다양한 사용자 프로파일을 감안한 개인화된 검색가중치를 적용하는 연구와 본 연구에서 제시된 새로운 시스템을 구축하여 기존의 검색엔진들과의 비교하는 실증적 접근, 특히 서버 및 클라이언트에 대한 사이트맵의 효과성 입증, 그리고 새로운 브라우징 패턴에 관한 연구 등이 필요하다.

참 고 문 헌

- [1] Abiteboul, S., Predal, M., and Cobena, G., "Adaptive On-Line Page Importance Computation," In Proc. *WWW*, (2003), pp.280-290.
- [2] Álvarez, M., J. Raposo, A. Cacheda, F. Bellas,

and V. Carneiro, "DeepBot : a Focused Crawler for Accessing Hidden Web Content," In Proc. *DEECS*, (2007), pp.18-25.

- [3] Bergman, M., "The Deep Web : Surfacing Hidden Value," *Journal of Electronic Publishing*, Vol.7, No.1(2001).
- [4] Batafogo, R., E. Rivlin, and B. Shneiderman, "Structural Analysis of Hypertexts : Identifying Hierarchies and Useful Metrics," *ACM TOIS*, Vol.10, No.2(1992), pp.142-180.
- [5] Brynjolfsson, E., A. Dick, and M. Smith, "Search and Product Differentiation at an Internet Shopbot," *MIT Sloan Working Paper*, No. 4441-03(2003).
- [6] Caldo, P., B. Ribeiro-Neto, and N. Ziviani, "Local Versus Global Link Information in the Web," *ACM TOIS*, Vol.21, No.1(2003), pp.42-62.
- [7] Chakrabarti, S., "Dynamic Personalized Page-Rank in Entity-Relation Graphs," In Proc. *WWW*, (2007), pp.571-580.
- [8] Chang, C., M. Kayed, M. Girgis, and K. Shaalan, "A Survey of Web Information Extraction Systems," *IEEE TKDE*, Vol.18, No.

- 10(2006), pp.1411–1428.
- [9] Cilibrasi, R., and P. Vitányi, “The Google Similarity Distance,” *IEEE TKDE*, Vol.19, No.3(2007), pp.370–383.
- [10] Eichmann, D., “The RBSE spider : Balancing Effective Search Against Web Load,” In Proc. *WWW*, (1994), pp.113–120.
- [11] Eiron, N., K. McCurley, and J. Tomlin, “Ranking the Web Frontier,” In Proc. *WWW*, (2004), pp.309–318.
- [12] Fu, Y., M. Creado, and C. Ju, “Reorganizing Web Sites Based on User Access Patterns,” In Proc. *CIKM*, (2002), pp.583–585.
- [13] Garofalakis, J., P. Kappos, and D. Mourloukos, “Web Site Optimization Using Page Popularity,” *IEEE Internet Computing*, Vol.3, No.4 (1999), pp.22–29.
- [14] Gouveia, L., “Multicommodity Flow Models For Spanning Trees with Hop Constraints,” *European Journal of Operational Research*, Vol.95, No.1(1996), pp.178–190.
- [15] Gyongyi, Z., P. Berkhin, H. Garcia-Molina, and J. Pedersen, “Link Spam Detection Based on Mass Estimation,” In Proc. *VLDB*, (2006), pp. 439–450.
- [16] Hammami, M., Y. Chahir, and L. Chen, “Web-Guard : A Web Filtering Engine Combining Textual, Structural, and Visual Content-Based Analysis,” *IEEE TkDE*, Vol.18, No.2(2006), pp.272–284.
- [17] Haveliwala, T., “Topic-Sensitive PageRank : A Context-Sensitive Ranking Algorithm for Web Search,” *IEEE TKDE*, Vol.15, No.4(2003), pp.784–796.
- [18] Henzinger, M.R., A. Heydon, M. Mitzenmacher, and M. Najork, “On Near-Uniform URL Sampling,” *Computer Networks*, Vol.33, No.1-6(2000), pp.295–308.
- [19] Henzinger, M.R., “Combinatorial algorithms for web search engines : three success stories,” In Proc. *SODA*, (2007), pp.1022–1026.
- [20] Ikeda, R., K. Zhao, and H. Garcia-Molina, “Matching Hierarchies Using Shared Objects,” In Proc. *ECDL*, (2008), pp.209–220.
- [21] John, J.C., and U. Schonfeld, “RankMass Crawler : A Crawler with High PageRank Coverage Guarantee,” In Proc. *VLDB*, (2007), pp.375–386.
- [22] Kawatra, R., “A Hop Constrained Min-Sum Arborescence with Outage Costs,” In Proc. *HICSS*, (2003), pp.2648–2656.
- [23] Kleinberg, Jon. M., “Navigation in a Small World”, *Nature*, Vol.406, No.6798(2000), p. 845.
- [24] Lin, C.C., “Optimal Web Site Reorganization Considering Information Overload and Search Depth,” *European Journal of Operational Research*, (2005), pp.839–848.
- [25] Meng, W., C. Yu, and k. Liu, “Building Efficient and Effective Metasearch Engines,” *ACM Computing Surveys*, Vol.34, No.1(2002), pp.48–89.
- [26] Miller, R., and k. Bharat, “Sphinx : A Framework for Creating Personal, Site-Specific Web Crawlers,” In Proc. *WWW*, (1998), pp.119–130.
- [27] Najork, M., and J.L. Wiener, “Breadth-First Crawling Yields High-Quality Pages,” In Proc. *WWW*, (2001), pp.114–118.
- [28] Najork, M., H. Zaragoza, and M.J. Taylor, “Hits on the Web : How Does It Compare?” In Proc. *SIGIR*, (2007), pp.471–478.
- [29] Novak, J., P. Raghavan, and A. Tomkins, “Anti-Aliasing on the Web,” In Proc. *WWW*, (2004), pp.30–39.
- [30] Ntoulas, A., Zerfos, P., and Cho, J., “Downloading Textual Hidden Web Content Through Keyword Queries,” In Proc. *ICDL*, (2005), pp.

- 100-109.
- [31] Pandurangan, G., P. Raghavan, and E. Upfal, "Using PageRank to Characterize Web Structure," In Proc. *COCOON*, (2002), pp.330-339.
 - [32] Perkowitz, M., and O. Eizioni, "Toward Adaptive Web Sites : Conceptual Framework and Case Study," *Artificial Intelligence*, Vol.118, No.1-2(2000), pp.245-275.
 - [33] Robertson, S.E. and S. Walker, "Some simple effective approximations to the 2-Poisson model for probabilistic weighted retrieval, ACM SIGIR, (1994), pp.232-241.
 - [34] Siganos, G., M. Faloutsos, P. Faloutsos, and C. Faloutsos, "Power Laws and the AS-level Internet Topology," *IEEE Transactions on Networking*, Vol.11, No.4(2003), pp.514-524.
 - [35] Varadarajan, R., V. Hristidis, and T. Li, "Beyond Single-Page Web Search Results," *IEEE TKDE*, Vol.20, No.3(2008), pp.411-424.
 - [36] Wookey, Lee and S. Lim, "Maximum Rooted Spanning Trees for the Web," OTM Workshops, Vol.2(2006), pp.1873-1882.
 - [37] Wookey, Lee, S. Kim, and S. Kang, "Structuring Web Sites Using Linear Programming," LNCS, (2004), pp.328-337.
 - [38] Xu, G., and W. Ma, "Building Implicit Links from Content for Forum Search," In Proc. *SIGIR*, (2006), pp.300-307.
 - [39] <http://www.websiteoptimization.com/>.
 - [40] <http://www.poweradmin.com/servermonitor/>.