

효율적인 홈페이지 관리를 위한 구조 분석 시스템의 설계 및 구현

최봉준, 박규석
경남대학교 컴퓨터공학과

Design and Implementation of A Structure Analyzer for Efficient Homepage Management

Bong Joon Choi Kyoo Seok Park
Dept. of Computer Engineering, Kyungnam University

요약

네트워크기술의 발달로 인하여 인터넷 이용자의 급증과 함께 그에 따른 정보를 제공하기 위한 인터넷 홈페이지도 기하급수적으로 증가하게 되었다. 인터넷 홈페이지의 운영 기간이 증가함에 따라 홈페이지를 구성하는 웹 문서와 웹 컨텐츠의 수도 증가하게 된다. 따라서, 이러한 웹 문서와 웹 컨텐츠에 대한 관리를 위하여 WCMS(Web Contents Management System)이 도입되고 있지만, WCMS에서는 웹 컨텐츠의 생성, 출판, 관리를 주요 기능으로, 웹 컨텐츠의 사용 횟수, 웹 문서의 다운로드 속도, 웹 문서 다운로드 용량, 데드 링크 여부 등을 분석하고 관리해 주는 소프트웨어가 필요하게 되었다.

본 논문에서는 웹 문서를 시각적으로 분석하여 웹 컨텐츠를 추출하고 웹 문서 내에서의 웹 컨텐츠 위치 및 크기를 분석한 후, 웹 컨텐츠의 연결 가능 여부를 분석하여 데드링크일 경우, 시각화하고, 웹 컨텐츠가 얼마나 사용되는지 등 홈페이지를 효율적으로 관리할 수 있는 구조 분석 시스템을 설계 및 구현하였다.

1. 서론

인터넷의 사용이 급증하면서 그 사용자의 다양한 욕구를 충족시키기 위한 서비스를 제공하는 홈페이지의 경우, 2003년 현재 전 세계적으로 약 4000만 개의 웹서버와 약 30억 개 이상에 이르는 웹 문서로 서비스되고 있다[2][3].

인터넷 홈페이지의 개설과 함께 증가된 웹 컨텐츠를 효율적으로 관리하기 위해 WCMS(Web Contents Management System)을 도입하여 웹 컨텐츠의 생성, 출판, 관리를 효율적으로 수행하고 있으나, 이러한 WCMS는 웹 컨텐츠 자체에 대한 관리를 효율적으로 수행하기 위한 방법으로 웹 문서의 시각적인 크기, 웹 컨텐츠의 다운로드 속도, 웹 문서의 다운로드 용량, 데드 링크의 여부 등 홈페이지 이용자의 측면에서 분석하고 관리해 주는 시스템이 필요하게 되었다.

인터넷의 홈페이지의 개설과 폐쇄가 자유롭게 이루어지고 있어 웹 문서에서 하이퍼링크로 연결되어 있

는 다른 홈페이지의 웹 컨텐츠가 웹 문서 생성 당시에는 연결이 가능하였으나, 일정 시간이 경과되면 홈페이지의 폐쇄로 인하여 연결할 수 없는 데드링크가 발생하게 된다.

따라서 홈페이지 관리자는 주기적으로 하이퍼링크를 분석하여 데드링크가 발생하였는지 확인하여야 하며 데드링크가 발생하였을 경우, 이를 웹 문서에 적용하여 해당 하이퍼링크가 존재하지 않는 링크임을 표시하거나 하이퍼링크를 삭제하는 등의 관리를 필요로 한다.

이러한 유지보수는 홈페이지 개설 초기에는 적은 비용으로 관리가 되어지나 시간이 경과함에 따라 웹 문서를 생성한 홈페이지 관리자도 해당 하이퍼링크를 찾아 수정하는데 상당한 시간이 소요되어 이로 인한 홈페이지 관리비용이 증가하게 된다.

본 논문에서는 웹 컨텐츠의 위치와 크기를 측정하고 하이퍼링크가 연결되지 않는 데드링크가 발생하였

을 경우, 이를 시각화하고 웹 문서 다운로드 속도, 웹 문서 다운로드 용량 등을 분석함으로서 홈페이지를 효율적으로 관리하기 위한 방법에 대해서 논의한다.

본 논문의 구성은 다음과 같다. 먼저, 2장에서는 홈페이지 구조를 분석하기 위한 기초 기술인 웹 로봇에 대해서 기술하고 3장에서는 웹 컨텐츠의 위치 및 크기를 측정하고 구조를 분석하는 시스템을 제안한다. 그리고, 4장에서는 구조를 분석하기 위해 웹 컨텐츠의 위치 및 크기 측정 방법을 구현하고 웹 문서의 구조를 시각화함으로서 홈페이지를 효율적으로 관리할 수 있는 시스템을 구축한다. 마지막으로 5장의 결론에서는 향후의 연구과제를 제시한다.

2. 웹 로봇

웹 로봇이란 원하는 정보를 얻기 위해 웹 상의 문서들을 검색하고, 참조되는 문서들을 재귀적으로 검색하면서 웹의 하이퍼텍스트 구조를 자동으로 추적하여 정보를 저장해 주는 프로그램을 말한다.

웹 로봇은 일반적으로 Spider, Web Crawler 등으로 불리기도 한다. 웹 로봇은 자동적으로 웹의 하이퍼텍스트 구조를 따라 다니며 문서를 추출하고, 재귀적으로 그 문서에 참조되는 다른 문서들을 추출하는 방식으로 동작하는 프로그램으로 정의된다. 인터넷에서 정보검색 서비스를 제공하려면 웹 문서를 수집해야 하는데, 웹 문서를 어떻게 수집하느냐에 따라 검색 결과도 크게 달라진다. 웹 로봇의 순회 방법에 따라 넓이 우선 순회(Breadth-First Traversal)와 깊이 우선 순회(Depth-First Traversal)로 나뉘어 볼 수 있다.

웹 로봇들은 통계 분석, 유지 보수, 미러링, 리소스 발견 등에 이용된다. 또한 웹 로봇은 상대 시스템에 과다한 부하를 초래하거나, 웹 로봇의 동작 오류, 다른 URL 검사시 웹 로봇 성능의 저하 등의 문제를 발생시킨다[5].

3. 홈페이지 구조 분석 시스템 설계

그림 1은 본 논문에서 제안한 구조 분석 시스템의 구성도이다.

웹 문서 다운로더는 웹 컨텐츠 데이터베이스로부터 분석할 웹 문서 목록을 가져와서 웹 문서를 다운로드 한다. 다운로드한 웹 문서의 다운로드 속도를 측정한 후, 웹 문서 표현기에 의해 웹브라우저와 동일하게 표현한다.




그림 1 시스템 구성도

웹 문서 분석기는 웹 문서를 parsing하여 이미지, 플레이시, 애플릿 등의 웹 컨텐츠와 하이퍼링크를 추출하고 웹 컨텐츠와 하이퍼링크가 표현된 위치와 크기를 분석하고, 가로와 세로의 크기를 픽셀 단위로 분석한다.

웹 문서에 대한 분석이 완료되면 웹 컨텐츠 분석기에 의해 추출된 웹 컨텐츠와 하이퍼링크에 대한 연결 가능 여부 및 웹 컨텐츠의 파일 타입, 파일 크기에 대한 분석을 마친 후, 웹 문서에 대한 다운로드 용량을 분석한다.

웹 문서 분석기와 웹 컨텐츠 분석기에 의해 분석된 정보를 웹 컨텐츠 데이터베이스에 저장한다.

스크린샷은 웹 문서에 대한 셈네일 화면을 제공하기 위하여 웹 브라우저와 동일하게 표현된 웹 문서를 캡처하여 이미지 데이터베이스에 저장하고 데드링크와 같이 연결이 불가능한 웹 컨텐츠와 하이퍼링크에 대한 화면을 캡처하여 이미지 데이터베이스에 저장하는 기능을 수행한다.

구조 분석 시작화는 웹 문서의 구조를 시각적으로 표현하기 위하여 셈네일 이미지를 보여주고, 웹 문서의 다운로드 속도, 파일 크기, 다운로드 용량 등의 기초 정보와 가로 세로의 크기를 픽셀 단위로 분석한 웹 문서의 크기 정보를 제공한다.

분석된 웹 컨텐츠와 하이퍼링크의 위치 및 크기 정보를 이용하여 웹 컨텐츠의 파일 타입, 파일 크기 등의 분석 정보를 제공하고, 하이퍼링크로 연결된 웹 문서나 웹 컨텐츠에 대한 분석 정보도 함께 제공된다.

데드링크의 관리를 위하여 데드링크에 대한 위치 파악이 쉽도록 시각화된 정보와 웹 컨텐츠의 파일 타입, 파일 크기 등의 분석 정보를 제공한다.

그림 2는 홈페이지에 대한 구조 분석 과정을 나타낸 것으로 11 단계에 의해 홈페이지의 모든 웹 문서와 웹 컨텐츠에 대하여 반복적으로 분석함으로써 완료된다.




그림 2 홈페이지 구조 분석 과정

◆ 홈페이지 구조 분석 단계

단계 1. Get Going URL

→ Going URL을 읽어온다.

단계 2. Analysis Contents for URL and Save

→ URL에 대한 컨텐츠 타입, 파일크기, 존재 여부를 분석하고 저장한다.

단계 3. Download or Goto 1

→ URL이 text/html이면 다운로드한다. 만약 데드링크면 저장하고 1을 수행한다.

단계 4. DOM Analysis(Anchor List, Contents List, Exposure)

→ 다운로드가 완료되면 URL을 분석하여 Anchor List와 Contents List를 추출한다.

단계 5. Save Gone / Delete Going

→ URL 분석이 완료되면, 현재 분석한 URL을 Gone URL에 저장하고, Going URL에서 삭제한다.

단계 6. Registered URL, Get URL ID for Anchor List

→ URL Table에 없는 URL을 등록하고 ID를 할당받는다.

단계 7. Save Anchor List

→ Anchor List에 대하여 노출위치 및 노출 크기 정보를 Anchor Table에 저장한다.

단계 8. Add Going URL

→ Going URL, Gone URL에 존재하지 않는 Anchor를 Going URL에 추가한다.

단계 9. Registered URL, Get URL ID for Contents List

→ Contents List를 읽어와 URL Table에 없는 목록을 URL로 등록하고 ID를 할당받는다.

단계 10. Analysis Contents for Contents List

→ Contents List에 대하여 컨텐츠 타입, 파일크기 및 존재 여부를 분석한다.

단계 11. Save Contents List

→ 분석한 Contents List에 대하여 노출위치 및 노출 크기 정보를 Contents Table에 저장한다.

4. 구현

그림 3은 본 논문에서 제안한 구조 분석 시스템의 실행 화면으로 현재 분석중인 웹 문서의 파일 타입, 파일 크기, 접속 속도를 분석하고 웹 문서에 포함된 이미지, 플래시 등의 웹 컨텐츠에 대한 파일 타입, 파일 크기 등을 분석하며, 하이퍼링크의 접속 가능 유무를 분석하여 접속이 불가능한 데드링크의 경우 데드링크된 하이퍼링크의 위치 크기를 분석하여 화면을 캡처한 후, 데이터베이스에 저장하는 기능을 수행한다.




그림 3 구조 분석 시스템의 구현 화면

그림 4는 구조 분석 시스템에 의해 생성된 웹 문서 정보를 HTML로 나타낸 것으로 웹 문서 제목, 컨텐츠 형태, 파일 크기, 다운로드 크기, 다운로드 시간, 문서 크기, 최종 변경 날짜, 웹 컨텐츠 수, 하이퍼링크, 참조 횟수 등을 나타낸 것으로 웹 컨텐츠에 대한 개별 분석 및 하이퍼링크에 대한 개별 분석 등의 정보도 제공한다.




그림 4 웹 문서 분석 정보

그림 5는 구조 분석 시스템에 의해 분석된 정보 중 데드링크가 포함된 웹 문서의 목록을 나타낸 것으로 웹 문서의 파일 타입, 파일 크기, 다운로드 크기, 접속 속도, 노출 크기, 데드링크 수 등의 정보를 제공한다.




그림 5 데드링크가 발생된 웹 문서 목록

그림 6은 본 논문에서 제안한 구조 분석 시스템에서 분석한 데드링크 정보를 시각적으로 표현한 화면으로 데드링크의 위치 및 크기를 픽셀로 분석한 후 캡쳐할 화면의 위치 및 크기를 설정한 후 화면을 캡쳐하여 이미지 데이터베이스에 저장한 다음, 저장된 데이터베이스를 조회하여 캡쳐된 이미지와 함께, 데드링크의 위치 및 크기 정보를 이용하여 시각적으로 표현한 화면이다.

그림 5와 그림6에 의해 제공된 데드링크를 포함한 웹 문서의 목록과 웹 문서에 포함된 데드링크의 시각화 정보를 이용함으로서 데드링크의 효율적인 관리가 가능해 진다.




그림 6 데드링크의 시각적 표현

5. 결론

본 논문에서는 더욱 복잡하고 다양해져 가는 인터넷상의 홈페이지를 효율적으로 관리하기 위하여 웹 문서를 분석하고 웹 컨텐츠 및 하이퍼링크에 대한 정보를 구조적으로 표현하며, 웹 문서 내에 포함된 데드링크를 탐지하여 이를 시각화함으로써 기존의 텍스트 기반에 의존한 데드링크 관리 보다 효율적으로 관리가 가능하게 되었다. 따라서, 본 논문에서 제안한 구조 분석 시스템을 홈페이지의 기능적 관리에 대한 데드링크 시각화 및 효율적인 홈페이지 구조 분석이 가능하도록 개선하며, 향후 연구 방향으로는 페이지 랭킹 알고리즘에서 웹 문서 내의 하이퍼링크의 위치 및 크기에 따른 웹 문서의 인기도 분석에 대한 연구가 필요하다고 하겠다.

[참고문헌]

- [1] <http://msdn.microsoft.com/workshop/samples/author/dhtml/overview/measure.htm>
- [2] <http://www.netcraft.com/>
- [3] <http://www.google.com/>
- [4] Suhit Gupta, Gail Kaiser, David Neistadt, Peter Grimm, "DOM-based Content Extraction of HTML Documents", Proceedings of the twelfth international conference on World Wide Web, May 20-24, 2003, pp.207-214
- [5] 김 일, "지역정보망을 위한 실시간 제어 검색엔진의 설계 및 구현", 경남대학교 석사학위 논문, 1999.2