분산 수집 모델을 이용한 웹 로봇의 설계 및 구현

김대유* · 김정태*

Design of Web Robot Engine Using Distributed Collection Model Processing

Daeyu Kim* · Jung-Tae Kim*

요 약

인터넷의 이용이 활발해짐에 따라 수많은 정보들이 웹을 통하여 공개되고 있으며, 이용자는 웹 검색 서비스를 이용하여 이러한 정보들에 효과적으로 접근할 수 있다. 웹 검색 서비스의 구축을 위해서는 웹 로봇을 사용한 웹 문서 수집이 선행되어야 하며, 웹 문서들의 수가 급격히 증가하면서 양질의 웹 문서들을 효과적으로 수집할 수 있는 웹 로봇에 대한 필요성이 증가되고 있으며, 그에 따른 많은 웹 수집 로봇이 탄생되고 있다. 본 논문에서는 효과적인 웹 수집 로봇의 설계와 동적인 웹페이지에서 사용하는 자바스크립트의 링크추출 방안을 제안하였다. 본 논문에서는 성능 분석을 위하여 제안된 모델을 사용하여 수집 모델을 1개로 설정해 놓고 299개의 웹 페이지를 점검하였을 경우, 2분 12.67초가 소요되었고, 수집 모델을 10개로 생성하여 점검하였을 경우 12.33초가 소요됨을 알 수 있었다.

ABSTRACT

As internet becomes widespread, a lot of information is opened to public and users of Internet can access effectively information using web searching service. To construct web searching service, the web searching method for collecting of information is needed to obtain web page view. As a number of web page view increases, it is necessary to collect information of high quality information to be searched, therefore, a variety of web engine for searching mechanism is developed. Method of link extraction with javascript in dynamic web page and design of web searching robot are presented in this paper. To evaluate performance analyzes, we fixed one searching model with the proposed method. The searching time takes 2 minute 67 sec for 299 web pages and 12.33 sec for 10 searching model.

키워드

분산 수집 모델, 웹 로봇 엔진, 자바스크립트

Key word

Web engine, Web searching robot, javascript

* 목원대학교

접수일자 : 2009. 06. 30
심사완료일자 : 2009. 08. 28

Ⅰ. 서 론

인터넷 이용이 활발해짐에 따라 수많은 정보들이 웹 문서의 형태로 공개되고 있으며, 이러한 웹 문서들을 효과적으로 검색하기 위하여 웹 검색 서비스들이 이용되고 있다. 웹 로봇은 지정된 URL 리스트에서 시작하여 웹 문서를 수집하고, 수집된 웹 문서에 포함된 URL들을 추출과정과 새롭게 발견된 URL에 대한 웹 문서 수집과정을 반복하는 소프트웨어로서 웹 검색 서비스의 구축을 위해서는 웹 로봇을 이용한 웹 문서 수집이 선행되어야 한다. 1990년대 중반의 웹 문서 수는 현재에 비하여 매우 적었기 때문에, 최초로 개발된 웹 로봇 Wanderer를 포함하여 이 당시 개발된 다수의 웹 로봇들은 대용량의 웹문서들을 수집하도록 설계되지 않았다[1,2.]

현재는 전 세계적으로 30억 개 이상의 웹 문서들이 존재하며, 국내에도 5천만 개 이상의 웹 문서들이 존재하고 있다. 따라서 이처럼 많은 수의 웹 문서들은 효율적으로 수집 할 수 있는, 즉 초당 수백 또는 수 천개의 웹 문서들을 수집 할 수 있는 웹 로봇의 필요성이 증가되고 있다[2]. 인터넷이 발달됨에 따라서 동적인 웹사이트가 증가하고 있다. 사용자들이 원하는 게시물을 등록하고, 삭제하고 수정할 수 있는 웹사이트가 증가됨에 따라서 웹 로봇은 이러한 특성들을 고려하여야 한다. 또한 동적인 웹사이트에서 사용되는 자바스크립트의 경우에는 기존에 사용되었던 정규표현식만으로는 찾아 낼 수 없다. 로봇은 URL을 통해서 웹 문서를 수집하게 되는데, 자바스크립트에 의한 링크를 URL로 생성할 수 없다는 많은 어려움이 있다. 웹 로봇 구현에 대한 연구는 웹 사이트에 대한 부하를 최소화 하면서 문서수집 속도를 최대화 하는 것을 중요한 목적이다. 또한 사이트 기반의 정적 또는 동적 웹 문서 수집을 하기 위해서는 동적인 링크(자바스크립트)를 처리 할 수 있어야 하며, 중복 URL처리 기술 또한 매우 중요한 기술이라 할 수 있다. 이미 수집되었던 웹 페이지를 중복으로 처리 하지 않기 위해서 이다. 본 논문에서는 웹 로봇 구현에 대한 고려되어야 하는 다양한 사항들에 대해서 테스트 하여 구현해 보았다. 첫째는 단일수집 로봇과 복수수집 로봇을 구현하여 테스트 하였고, 또한 자바스크립트의 함수를 실행하여 그 결과를 페이지 주소로 구현하고 하였다.

Ⅱ. 관련연구

웹 로봇에서 중요한 모델로는 수집모델, URL중복처리 모델, HTTP 헤더분석 모델이 있다. 수집모델은 웹 페이지의 헤더를 분석하고 문서의 정보를 처리 하는 부분이다. URL중복처리 모델은 웹 로봇이 한번 방문 하였던, 웹 페이지를 다시 방문하지 않도록 하는 모델이이다[3]. 그림 1은 기본적인 로봇의 구조를 보여주고 있다.

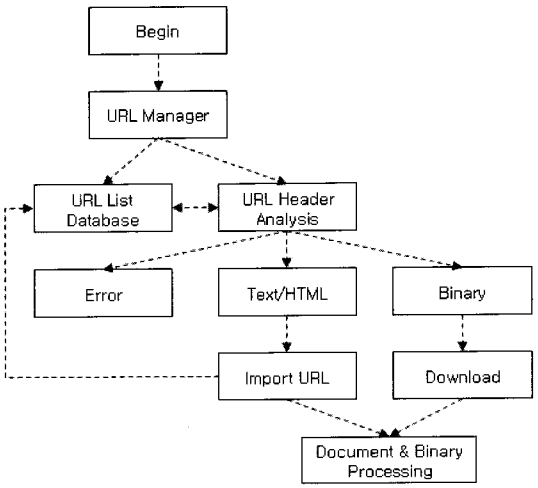

그림 1. 기본적인 로봇 시스템 구조
Figure 1. Structure of basic robot system

2.1 수집모델

수집모델은 웹 페이지를 다운로드 하여 정보를 각 로봇에 따라 처리하게 하는 모델이다. 웹 로봇은 씨앗(Seed) URL들에서 시작하여, 이들로부터 접근 가능한 모든 웹 문서들을 수집한다. 네트워크의 속도 저하, DNS 서버의 장애, 특정 웹 사이트에서의 일시 점검 등으로 인하여, 접속의 장애가 발생할 경우가 발생되는 문제점일 발생될 수 있으므로, 수집모델은 멀티쓰레드 방식이 적절하다고 볼 수 있다. 그림 2는 기본적인 수집모델의 구조를 보여주고 있다.

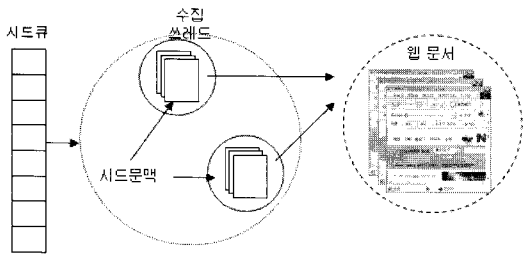

그림 2. 수집모델
Figure 2. Collecting model

2.2 URL중복처리 모델

수집모델을 실행시키기 전에 수집하려는 페이지가 사전에 수집정보를 검사 하고, 수집이 되지 않았다면 수집모델로 수집하려는 페이지의 URL정보를 요청하게 된다. 중복처리 모델은 주로 Databases에에 삽입하고 테이블의 필드 정보에 Uniquee 설정을 통하여 간편하게 할 수 있다.

2.3 헤더분석 모델

HTTP헤더의 정보를 분석하여, 해당 URL주소가 파일로 연결된 URL일 경우 다운로드를 하여 파일로 저장하게 하며, html/text 포맷일 경우 각 로봇의 특성에 따라 처리 한 뒤 수집한 웹 문서내의 URL정보를 추출하여 URL 중복처리 모델로 넘기게 된다. 또한 네트워크의 장애가 발생되는 문제점을 파악할 때 사용된다.

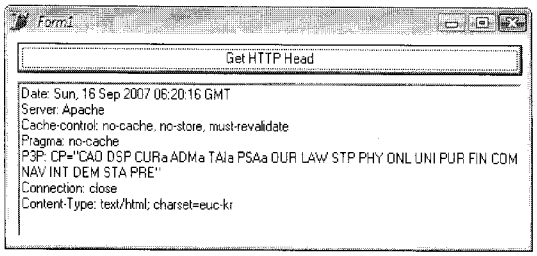

그림 3. HTTP 헤더 정보
Figure 3. Collecting model

위의 그림 3은 'http://www.naver.com' 주소의 헤더정보를 나타낸 것이다. Content-Type정보를 통하여 text/html 혹은 Application 정보를 분석하여 파일의 정보를 알 수 있다. 또한 웹 서버의 정보나 웹 페이지 갱신 날짜를 알 수 있다. 갱신정보는 웹 사이트를 다시 방문할 때 기존 정보와 비교하여 페이지의 갱신정보를 비교하여 재분석하지 처리 결정에 있어 사용할 수 있어 매우 유용 하다. [4]

Ⅲ. 제안된 웹 로봇 모델의 구현

3.1 헤더분석 모델 구현

해더분석은 단순히 HTTP소켓을 가지고 정보를 가져올 수 있으며, HTTP 헤더의 정보 중에 Content-Type의 내용이 text/html 일 경우 분석처리 모델로 내용을 전달하고 Application Data 경우, 다운로드 처리 모델로 전달하여 처리 하도록 하는 역할을 하기도 한다. 또한 접속이 불가능 할 경우 페이지 에러 처리가 가능해야 한다. 소켓이 에러 났을 경우 Try ... Except 구문으로 처리 할 수 있다. HTTP소켓 에러의 메시지 정보는 'http://www.w3.org/Protocols/rfc2616/rfc2616-sec10.html'에 상세히 표기 되어 있다. 네트워크의 상태에 따른 예외처리가 잘 되어 있지 않으면 잘못된 페이지를 처리하기 위한 수집 모델이 Dead Lock 상태로 빠질 수 있기 때문에 상태에 따른 Excpet(예외)처리가 잘 되어 있어야 한다. 페이지 요청 후 접속이 되었을 경우 헤더의 정보를 다운로드 받는 부분의 예외처리와 헤더 정보를 다운로드가 정상적으로 처리 된 후 문서를 다운로드 받는 부분의 예외처리 또한 되어 있어야 한다.

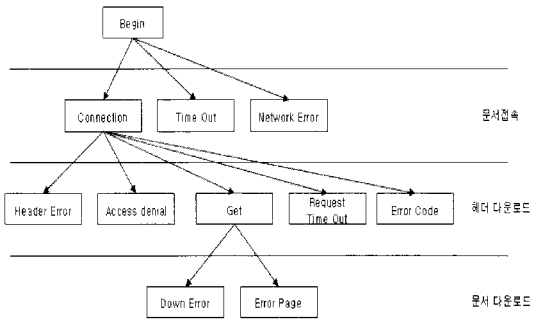

그림 4. 네트워크 상태도
Figure 4. Status of network

헤더의 정보를 가져오는 예제코드는 매우 간단하게 구성 할 수 있다. IdHTTP Socket을 생성한 뒤에, idHTTP의 헤더 정보를 가져오면 되기 때문이다. 그림 5에서는 파스칼 형식의 예제코드를 나타내고 있으며 그림 6에서는 해당 함수를 실행 한 결과를 나타내고 있다.

3.2 수집 쓰레드 처리 모델

쓰레드(Thread)는 주로 프로세스(실행되고 있는 프로그램)에서 만들어진다. 만약, 하나의 데이터가 있다고 가정하면. 이 데이터를 서로 다른 방법으로 처리하면서 결과 값 을 주고받아야 합니다. 하지만 프로세스는 서로의 영역에 통신을 할 수 가없습니다. 그때 프로세스가 통신을 위해 파생시키는 것이 쓰레드(Thread) 이다. 쓰레드는 메모리의 같은 공간을 공유하고 있으므로 하나의 쓰레드(Thread)에 이상이 있으면 다른 쓰레드(Thread)에도 영향을 주게 됩니다.

```
Function GetURLType( URL : String ) : String;
Var
  stList : TStringList;
  iCnt   : Integer;
Begin
  Try
    tcp80 := TidHTTP.Create(nil);
    tcp80.Head(URL);
  Except

  End;
  stList := TStringList.Create;
  stList.Text := tcp80.Response.RawHeaders.Text;

  For iCnt := 0 to Pred(stList.Count) Do
  Begin
    Form1.ListBox1.Items.Add('List Count [' + IntToStr(iCnt) + '] ' +  stList[iCnt]);
  End;


  Result := stList.Text;
  tcp80.Free;
  stList.Free;
End;
```

그림 5. HTTP 헤더의 예제
Figure 5. HTTP Header Sample

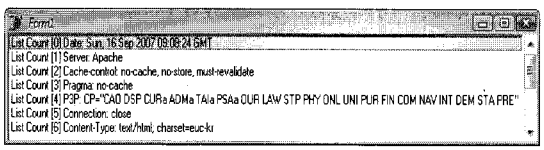

그림 6. 수집된 HTTP 헤더의 결과
Figure 6. Result of collective HTTP Header

대개의 경우 프로세스는 단독으로 실행이 가능하지만 쓰레드는 프로세스가 있고 그 하위에 쓰레드가 여러 개 생성되는 것이 일반적입니다. 같은 메모리 공간을 사용할 때 문제의 발생을 줄기 위해서 쓰레드 락(Thread Lock)이라는 프로그래밍 또한 가능하며 또한 쓰레드 방식은 2가지의 방식이 있는데, 싱글 쓰레드 방식과 멀티 쓰레드 방식이 있습니다. 독립적으로 1개의 메소드(Method)만 호출 하는 것을 싱글 쓰레드 방식 싱글 쓰레드 방식은 멀티 쓰레드 방식보다 처리 속도가 빠르며, 쓰레드 락(Thread Lock)에 대한 고려또한 필요가 없다. 2개 이상의 메소드(Method)를 동시에 호출 할 때에는 멀티 쓰레드 방식이라고 합니다. 멀티 쓰레드 방식은 쓰레드 리스트(Thread List)라는 큐를 가지고 있으며 싱글 쓰레드 방식과 멀티 쓰레드 방식으로 작업을 처리 하게 되면 싱글 쓰레드 보다 처리 속도가 늦습니다. 이유는 바로 CPU Context Switching 작업이 추가되기 때문이다.

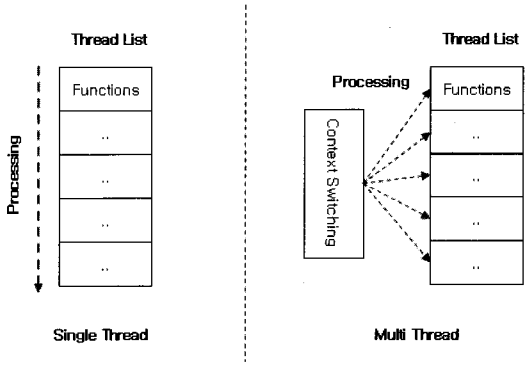

그림 7. 싱글, 멀티 쓰레드의 처리방법
Figure 7. Processing method of single and multi thread

90개의 웹 페이지를 생성하여 업로드 한 뒤에, 멀티쓰레드 방식과 싱글쓰레드 방식으로 테스트 한 결과 멀티 쓰레드 방식은 9.250 Sec 이 소요 되었으며, 싱글 쓰레드 방식은 15.578 Sec 이 소요 되었음을 알 수 있습니다. 만약 웹 사이트에서 네트워크 장애가 발생하였을 경우 싱글 쓰레드의 경우에는 소요시간이 더 지체 될 수 있다. 또한 점검하려는 대상의 사이트가 많아지는 경우에는 소요 시간의 차이가 더욱 커지게 된다.

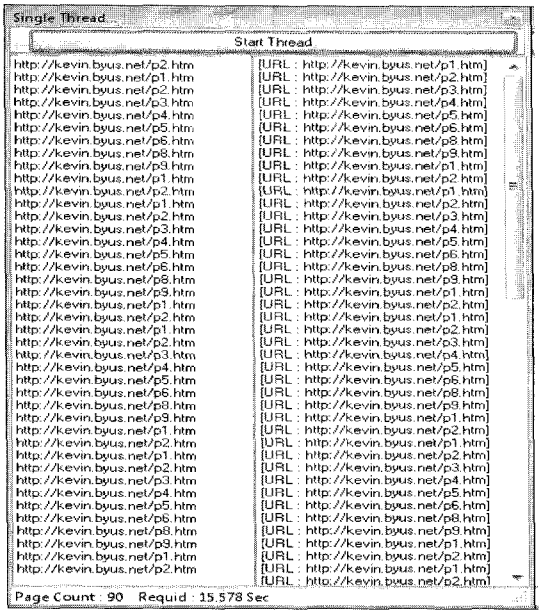

(a)

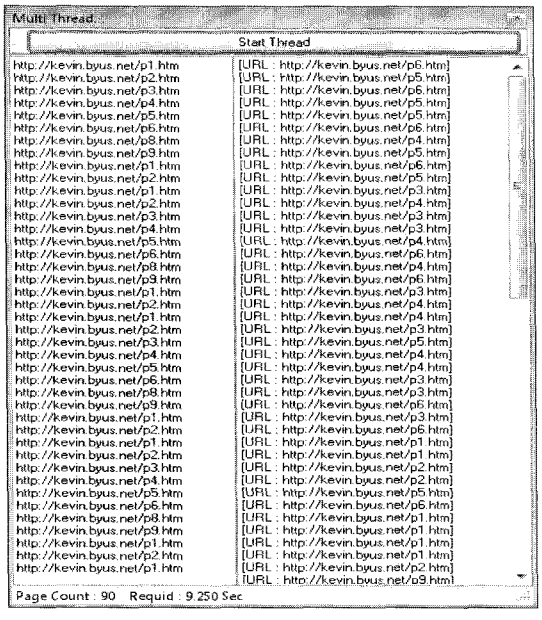

(b)

그림 8. 멀티쓰레드 방식과 싱글쓰레드 방식 처리 속도 비교

Figure 8. Comparison of processing speed with single and multi thread

싱글쓰레드 구현부...

```
type
  TRunThread = class(TThread)
  tcp80 : TidHTTP;
  protected
    procedure Execute; override;
    procedure Running;
end;
...

  for iCnt := 0 to Pred(Memo1.Lines.Count) do
  begin
    pURL     := Memo1.Lines[iCnt];
    RunThread := TRunThread.Create(False);
    RunThread.Priority := tpLower;
    RunThread.Resume;
    RunThread.WaitFor;
    Application.ProcessMessages;
  end;
```

멀티쓰레드 구현부...

```
type
  TPThread = class(TThread)
  private
    pURL : String;
    tcp80 : TidHTTP;
  protected
    procedure Execute; override;
  public
    constructor Create( argURL : String );
    destructor Destroy; override;
  end;
      ...

  for iCnt := 0 to Pred(Memo1.Lines.Count) do
  begin
    TPThread.Create(Memo1.Lines[iCnt]);
  end;
```

수집 모델의 개수에 따른 처리 속도를 비교하였을 경우, 속도의 차이가 확연하게 차이가 난다. 하지만 점검하려는 웹 서버의 설정이나 성능에 따라서 문제가 발생할 수 있다. 수집 모델이 많을 경우 IDS나 IPS 등에서 치단을 당할 수 있으며, IDS나 IPS가 없을 경우 서버가 다운될 수 있으며, 점검하려는 컴퓨터의 사양에 따라 차이가 날 수 있다.

수집 모델의 개수와 네트워크 상태에 따라 달라질 수가 있어 이러한 문제를 해결하기 위하여 내부의 네트워크에 연결된 서버의 웹 사이트를 대상으로 테스터 하였다. 수집 모델을1개로 설정해 놓고 299개의 웹 페이지를 점검하였을 경우, 2분 126.27초가 소요되었고, 수집 모델을 10개로 생성하여 점검하였을 경우 12.33초가 소요됨을 알 수 있다.

3.3 스크립트 처리 모델

웹 사이트에서는 문서와 문서와의 연결을 링크로 하게 됩니다. <a href="문서경로">로 표기 되는데, 이것을 하이퍼링크라고 합니다. 웹 로봇이 하이퍼링크를 추출하는 방법은 정규표현식으로 하게 되는데 하이퍼링크를 추출하는 정규 표현식은 (그림 3.3)과 같다.이렇게 정규표현식을 사용하여 링크를 추출하게 되는데, 몇 가지 문제가 있을 수 있습니다. 그 문제는 바로 자바 스크립트 함수를 호출하여 사이트를 연결해서 사용 할 수 있기 때문입니다.

<a href="javascript:this.href='./mokwon.php'"> 이와 같은 링크에서는 로봇에서 링크를 추출하지 못하는 문제가 발생 됩니다. 이런 자바스크립트를 위해서 웹 브라우져 객체와 MS MHTML 를 사용하여 처리 할 수 있습니다. Microsoft에서 제공하는 MS HTML는 HTML파서의 기능을 가지고 있으며, Web 객체를 사용하기 위해서는 별도의 Embedded Web Componuts (http://www.bsalsa.com/intro.html)를 사용 하였습니다. IHTMLWindow2에 Web 객체를 삽입한 뒤에, 스크립트를 실행하면 웹 객체가 BeforeNavigate 함수를 호출하게 되는데 이때에 URL 정보와 PostData 정보를 가지고 자바스크립트 함수로 이동되는 URL을 알 수 있다. 웹 로봇을 구현하기 위해서 사용되는 모델 중, 자바스크립트 처리 모델에서는 메모리 누수 문제가 있는데, 이 문제는 구현에 사용되는 Embedded Web Componuts (http://www.bsalsa.com/intro.html)는 자체적인 문제로 로봇을 제작 하는데 사용하기에는 문제가 있다. 또한 수집 모델에서 사용되는 쓰레드 모델 처리 후 웹 사이트를 분석하는 기타 알고리즘을 구현하는데 있어서 쓰레드로 수행되어도 문제가 없어야 하도록 구현해야 하므로 이러한 부분을 고려해야 할 것이다. 또한 CPU Core와도 많은 차이가 있었다. Single Core에서 싱글, 멀티 쓰레드를 돌렸을 경우에는 Single Core의 경우 속도 차이가 거의 없었으며, Dual Core 에서는 수집 속도의 차이가 조금 더 많이 났으며, Quad CPU의 경우에는 Dual Core 보다 더 많은 차이가 났다. 웹 로봇을 어떤 작업환경에서 동작시키느냐에 따라서 수집모델의 Thread Counter를 결정해야 한다.

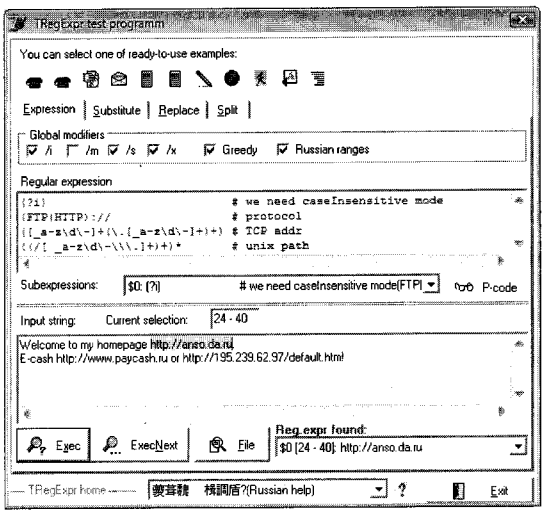

그림 9. 정규표현식을 통한 링크 추출
Figure 9. Extraction of link through normal basis expression

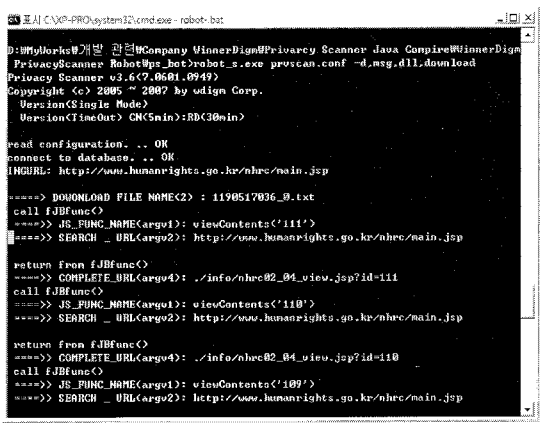

그림 10. 자바스크립트 처리 실행 화면
Figure 10. Screen of processing execution for javascript

Ⅳ. 결론

본 논문에서는 자바스크립트 함수를 포함한 웹 수집 로봇 설계 및 구현을 설계하였다. 앞으로도 웹 로봇은 웹 사이트 수집뿐만 아니라 다른 여러 분야에서 응용 할 수 있기 때문에 더 많은 연구가 필요 할 것이다. 본 논문에서는 수집모델을 사용하여 싱글과 멀티스레드 방법을 이용하여 제안된 모델을 성능평가를 하기 위하여 웹 로봇을 구현하여 테스트하였으며, 또한 웹 문서에 링크로 연결되어있는 자바스크립트 함수 처리 모델을 구현하였다. 성능 분석을 위하여 제안된 모델을 사용하여 수집 모델을 1개로 설정해 놓고 299개의 웹 페이지를 점검하였을 경우, 2분 126.27초가 소요되었고, 수집 모델을 10개로 생성하여 점검하였을 경우 12.33초가 소요됨을 알 수 있었다. 향후 연구 과제로는 링크수집 모델이 쓰레드 모델처럼 더 정형화 되어야 한다. 플래시로 구현된 사이트의 경우에는 웹 로봇이 하이퍼링크를 수집 못하는 문제점을 가지고 있어 플래시의 링크추출을 위한 링크추출 모델에 연구가 필요하다.

참고문헌

[1] 김광현, 이준호, "웹 로봇의 성능 평가를 위한 방법론", 정보처리학회, 제11D권, 제3호, 2006, pp.563-570

[2] Kwang Hyun Kim, "A Methodology for Performance Evaluation of Web Robot, Korea Information Processing Society Vol. 11, No. 3, June pp. 563-565, 2004

[3] Beitzel et al., 2007 Beitzel, S. M., Jensen, E. C., Lewis, D. D., Chowdhury, A., & Frieder, O. (2007). Automatic classification of Web queries using very large unlabeled query logs. ACM Transactions on Information Systems, 25(2), Article No. 9.

[4] Özmutlu et al., 2002 H.C. Özmutlu, A. Spink and S. Özmutlu, Analysis of large data logs: An application of Poisson sampling on excite Web queries, Information Processing & Management 38(4) (2002), pp. 473 - 490.

저자소개

김대유(Dae-Yoo Kim)

2006년 2월 : 목원대학교 전자공학과 학사
2006년 3월 ~ 2008년 2월 목원대학교 전자공학과 석사
2008년 3월 ~ 현재 : 목원대학교 전자공학과 박사과정 및 (주)위너다임 연구원
※관심 분야: 웹보안, 개인정보보호, 프라이버시 시큐리티

김정태(Jung-Tae Kim)

2001년 8월 : 연세대학교 대학원 전자공학과 박사
1991년 8월 ~ 1996년 2월 : 한국전자통신연구원(ETRI) 선임연구원
2002년 9월 ~ 현재 : 목원대학교 전자공학과 교수
※관심 분야: Information security system design, Network Security, ASIC Design.