

유해정보 차단 시스템 설계와 구현에 관한 연구

심재권*, 이진관*, 한경록*, 박기홍*

*군산대학교 컴퓨터 정보과학과

e-mail : seekman@kunsan.ac.kr

A Study on Design and Implementation of Intercepting System on Hurtfulness Information

Jae-Kwon Shim*, Jin-Kwan Lee*,

Kyoung-Lok Han*, Kihong Park*

*Dept of Computer Information Science, Kun-San University

요약

본 논문은 심각한 문제를 일으키고 있는 유해 정보들이 인터넷을 통해 무분별하게 제공되기 때문에 우리의 청소년들이 접근을 차단할 수 있는 시스템의 설계와 구현에 관한 연구이다. 유해 정보를 차단하기 위해 여러 차단 소프트웨어들이 개발되어서 기존의 차단 소프트웨어들은 차단 목록 데이터베이스를 사용해서 목록에 있는 경우 차단을 하거나 등급 표시에 따르도록 한다. 차단 목록 데이터베이스의 지속적인 업데이트, 등급 표시에 따른 오류나 사진 검열 등이 문제점으로 나타났다. 이 문제점 해결을 위해 본 논문에서는 사이트 상에서 제공되어지는 내용을 AC 머신을 이용하여 유해 단어를 추출하고 유해 정보 데이터베이스를 이용해서 유해 단어에 가중치를 부여했다. 그 결과로 유해 정보를 포함한 사이트는 90%의 차단률을 보여 효율적인 시스템으로 판명되었다.

1. 서론

인터넷은 급속한 발전 속에서 인터넷 홈페이지와 이메일을 통한 정보의 교환에서부터 화상, 음성 채팅을 통해서, 증권과 뉴스 등의 실시간 정보 제공, 음악과 동영상의 공유 등 여러 분야에서 인터넷은 빠른 신속성과 편리함을 제공하고 장소와 시간적 장벽을 극복한 금융거래 등을 할 수 있는 장점이 있는 반면, 개인정보의 유출, 인터넷 사기 등의 보안문제와 인신 공격과 유해한 정보의 홍수라는 단점이다. 성, 폭력, 살인, 마약 등의 불건전한 정보가 아이들부터 성인에 이르기까지 아무런 여과없이 제공되고 있다. 이런 이유로 인터넷을 통해 제공되는 음란, 폭력, 자살, 마약에 대한 유해한 정보를 차단하는 도구 개발에 대한 관심이 고조되고 있으며, 전 세계의 어느 곳에서나 인터넷을 사용하

기 때문에 특정 국가에서 법·제도로서 규제하기는 어려우므로 기술적으로 유해한 정보를 차단할 수 있는 소프트웨어를 개발 및 보급하고 있다. 그 대표적인 예가 등급표시제와 차단 목록 기반의 유해 정보 차단 소프트웨어이다. 등급표시제는 사이트에 등급을 표시해서 성인용과 청소년용으로 나누는 것이며 차단 목록 기반의 유해 정보 차단 소프트웨어는 차단 목록 데이터베이스를 이용해서 데이터베이스에 있는 사이트를 접속하면 차단하는 소프트웨어이다. 등급표시제는 등급을 표시하는 기관이나 사람에 의한 오류와 사진 검열이라는 문제점이 있으며 차단 목록 기반의 유해 정보 차단 소프트웨어는 차단 목록의 계속적인 업데이트가 이루어져야 한다는 것이다.

본 논문에서는 사이트 상에서 제공되어지는 내용을

가지고 명사를 추출하는 AC 머신과 유해 정보 데이터 베이스를 이용해 사이트의 유해성을 판단하는 시스템을 구축했다.

본 논문에서는 유해 정보를 차단하기 위한 전 단계 작업으로 유해 정보의 차단 목적과 유해정보의 유형에 대해 2장에서 다뤄지며 3장에서는 유해 정보 차단 시스템의 설계와 구현에 대해서 마지막으로 4장 향후 과제 및 결론에서는 유해 정보 차단 시스템의 테스트 결과와 향후 추가되어야 할 사항들에 대해서 제시한다.

2. 유해 정보의 차단 목적과 유해 정보의 유형

2.1 유해 정보의 차단 목적

섹스, 폭력, 살인, 마약 등의 심각한 유해 정보들이 난무하는 인터넷이라는 통로를 통해서 아무런 여과없이 어린 청소년들로부터 나이드는 성인까지 무분별한 유해 정보의 제공이 이루어지고 있다. 이로써 사회적으로 심각한 문제를 일으켜 청소년들의 성매매, 강간, 살인, 마약, 청부살해, 자살, 모방범죄 발생되고 있다. 이로 인해서 더 이상은 유해 정보에 청소년들이 노출되지 않도록 막고자 하는 것이 목적이다.[1]

2.2 유해 정보의 유형

유해 정보로서 많이 나타나는 유형은 다음과 같다. 누드 또는 포르노 사진 일명 야사로 통하며, 포르노 동영상 일명 야동으로 통한다. 또한 야설이라고 지칭하는 섹스소설, 강간소설, 타부, 근친상간소설 등등이 있으며, 성폭력이나 살인을 조장, 살인청탁을 받는 홈페이지나 카페나 커뮤니티, 인터넷 자키, 웹 자키가 방송을 이끌어 나가는 성인용 인터넷 방송, 마약류에 대한 정보로 코카인이나 헤로인(히로뽕), 아편, 대마초, 신종 마약인 도리도리(MDMA), LSD, 엑스터시, 야바 등에 대한 사용을 조장하는 사이트나 카페, 커뮤니티의 등장을 볼 수 있다. 좀 더 세부적으로 유해 정보의 유형을 나눈다면 다음과 같다.

2.2.1 성인용 전자게시판

가장 많은 사람들이 이용하는 전자게시판 중 한 군데는 무려 2만5천 건에 달하는 사진 파일을 게시하고 있는데 대부분이 폭력성이 짙은 사진이나 성기가 노출된 사진이다. 이 게시판의 운영자는 로버트 토마스라는 사람으로 현재 구속 수감중이다. 다행이 이러한 전자게시판들은 대부분 상업적인 목적으로

운영되기 때문에 경제적인 능력이 없는 아이들이 접속하기는 쉽지 않다.

2.2.2 유즈넷 뉴스그룹

유즈넷 뉴스그룹이 익명으로 불법적인 음란물을 거래할 수 있는 장소로 변질되고 있다. 이곳은 내용을 열람하는데 아무런 비용도 들지 않는다. 유즈넷은 누구든지 자유롭게 문서나 그림파일을 올릴 수 있기 때문에 음란물에 중독된 사람들이 자신이 가지고 있는 자료들을 올리고 다른 사람의 자료를 받을 수 있는 무료로 교환할 수 있다. 음란물은 일종의 마약 같아서 일단 한번 접하게 되면 좀더 새롭고 자극적인 것을 보고자 하는 욕구가 생기게 된다. 그렇기 때문에 음란 사진들을 수집하는 사람들에게는 유즈넷은 아주 효과적인 자료 교환 장소이다. 음란물을 취급하는 유즈넷그룹의 명칭은 대개 'alt.sex' 또 'alt.binaries.pictures.erotica' 등 두 가지로 시작한다. 여기서 접하는 사진은 마치 사진 잡지나 비디오를 보는 것처럼 선명하다. [2]

2.2.3 WWW

대부분의 음란사이트들은 일단 접속하면 사용자가 18세를 넘었는지 확인한다. 그런데 이것은 형식에 불과한 절차여서 사용자가 아무리 어렵도 '예(yes)'를 클릭하기만 하면 홍보용 무료사진을 볼 수 있으며 결제용 신용카드번호와 비밀번호의 입력을 요구받게 된다. 물론 일부 사이트들은 사용자의 나이를 확인하는 절차를 거친 후에 홍보용 무료사진을 보여주기도 하지만 이는 그나마 양심적인 경우에 속한다. [3]

2.2.4 대화방(chat room)

인터넷에서 무료로 이용할 수 있는 서비스 중 하나가 대화방이다. 대화방도 이기적인 사람들에 의하여 악용되고 있으며 자신의 성적 욕망을 채우려는 사람들이 대화방 이곳 저곳을 기웃거리며 회색양을 찾아 헤매고 있다. 그런데 문제는 이들을 제재할 만한 방안이 거의 없다는 것이다. 특히 위험한 것은 메모와 인터넷 릴레이 채팅(IRC; internet relay chat)과 사설통신망 등에서 운영하는 대화방이다.[4, 5, 6, 7]

2.2.5 비디오 컨퍼런스(video conferences)

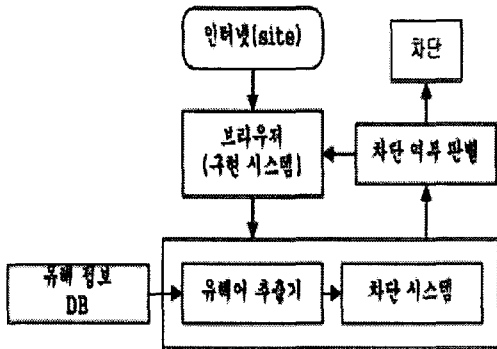
인터넷을 통한 화상 전달기술이 발달되면서 인터넷

넷을 통해 다른 곳에서 일어나는 상황을 실시간으로 관찰하는 것이 가능하게 되었다. 이러한 기술의 발달로 자신의 컴퓨터에 설치된 동영상 카메라 앞에서 미성년자를 추행하면 다른 사람들은 그 상황을 실시간에 볼 수 있게 된다.[6, 7]

3. 유해 정보 차단 시스템의 설계와 구현

3.1 유해 정보 차단 시스템의 설계

3.1.1 차단 시스템의 구성도



유해 정보 차단 시스템 구성도

시스템의 기본 구성은 유해 정보를 가지고 있는 사이트를 접속하면 인터넷 브라우저 상에서 바로 사이트를 나타내지 않고 접속하려는 사이트를 분석해서 구문분석기와 유해 정보 데이터베이스를 이용해 사이트의 차단 여부를 판단하도록 하는 것이다.

AC 머신을 이용해서 태그를 제거한 소스로부터 명사 목록을 추출해낸다.[8, 9, 10, 11, 12]

3.1.2 가중치 부여

AC 머신을 이용해 추출한 명사 목록을 유해 정보 데이터베이스에 있는 단어들과의 매치로 확인하고 추출된 유해 단어들의 가중치를 부여해 준다. 유해 단어에 가중치를 부여한 기준은 다음과 같다.

가중치	가중치 부여 기준
1	일상 용어(예: 학교, 친구)
2	성에 관한 연상 용어(예: 물건, 음수, 구멍)
3	신체 관련 연상 용어(예: 음모, 질구, 가슴)
4	성에 관한 직접적인 용어(예: 강간, 애무)

가중치 부여 기준표

3.2 구현 과정

다음의 구현 시스템은 브라우저의 주소 입력창을 통해서 입력된 주소와 주소의 소스를 파일로 저장하고 사이트의 소스를 분석할 수 있도록 태그 등을 제거해 구문 분석기의 데이터로 활용한다. 구문 분석기와 유해 정보 데이터베이스를 이용해 접속한 사이트의 유해성 가중치를 계산해 유해성 여부를 판단하여 차단하도록 한다.

실행시에 생성되는 파일들은 주소를 저장한 파일과 소스를 저장한 파일, 소스로부터 태그를 제거한 파일이 생성된다.

AC 머신으로 구성된 유해어 사전을 이용해 태그를 제거한 소스로부터 유해어를 추출해서 각 단어들이 가진 가중치를 계산해낸다. 유해 정보의 판단 근거는 단어들은 경험치에 의해서 추출했으며 가중치 또한 경험에 의해서 1 ~ 4 까지의 값을 부여했으며 태그 제거한 소스를 분석할 때 가중치의 평균을 구해서 경험치에 의한 평균값 1.5 이상을 넘을 경우 그 사이트는 유해 정보 사이트로 판명해서 차단하고 1.5 미만은 청소년들이 접속해도 무해한 사이트로 규정한다.

3.3 예

예를 들어서 다음의 문장을 AC 머신과 유해 정보 데이터베이스를 이용해서 유해어의 가중치를 계산하고 그 결과를 나타내면 다음과 같다.

예문	학교 때 친구들의 야한 농담에도 반응하여 음부가 젖곤하여 하루에도 두 번씩 팬티를 갈아 입어야할 적도 있었다.
명사 추출	학교 친구 농담 반응 음부 하루 팬티
유해 정보 가중치 부여	학교 1 친구 1 농담 2 반응 2 음부 4 하루 1 팬티 2
판단 결과	가중치의 합 / 명사 추출 개수 13/7 = 1.86

예제

유해 정보를 나타내는 단어가 사이트의 전체를 차지하는 것이 아니기 때문에 경험적으로 가중치의 평균이 1.5 이상일 경우 유해 정보로 분류했다. 위의 예를 보면 가중치의 평균이 1.86이므로 유해 정보로 판단했다.

3.4 평가

제한된 유해 정보 차단 시스템의 평가를 위해서 100개의 사이트를 방문해 보았다.

실험을 위한 환경은 펜티엄 III 733 MHz, 128 MByte의 메모리의 PC에서 Visual C++ 6.0으로 구현 및 평가했다.

	결과	차단률	
		적절	부적절
유해 ○	73%	90%	10%
유해 ×	27%	95%	5%

무작위로 여러 사이트를 방문해본 결과 유해 정보 사이트를 차단하는데 90% 정도의 차단률을 보였다. 그러나 유해 정보를 제공하지 않는 사이트에 대해서도 5% 정도가 차단되는 문제점이 발견되었다. 이로써 본 논문에서 구현한 유해 정보 차단 시스템은 유해한 정보를 갖고 사이트를 차단하는데 효율적인 시스템이다.

4. 결론

본 논문에서는 유해 정보를 가진 사이트를 차단하는데 접속을 시도하는 사이트의 소스를 AC 머신과 유해 정보 데이터베이스를 이용해 차단하려는 시도를 했다. 아직은 미비한 점이 많지만 따로 소프트웨어를 설치하지 않아도 인터넷 브라우저를 통해서 자동으로 유해 정보 사이트를 차단할 수 있도록 했다. 기존의 차단 소프트웨어에서 볼 수 없는 내용 분석 기반의 AC 머신을 이용해 유해 단어를 추출하고 유해 정보 데이터베이스를 가중치를 부여하여 효율적으로 유해 정보 사이트를 차단하였다. 향후 본 논문에 추가로 인터넷 사용자들이 느끼지 못하는 아주 짧은 시간에 차단 여부를 판명할 수 있는 차단 시스템을 구현하도록 하겠다.

참고문헌

[1] 류광재, “침입탐지에 의한 실시간대 인터넷 해킹 방지 연구”, 명지대학교 컴퓨터공학부, 석사학위 논문, 1996

[2] 성장열, “네트워크 모니터링과 MAPI를 적용한 웹 메시징 시스템 설계에 관한 연구”, 대전대학교대학원, 석사학위 논문, 2000

[3] 김현중, “HTML을 지원하는 라이브러리를 이용한 웹 문서 생성 시스템의 설계 및 구현”, 이화여자

대학교 대학원 전자계산학과, 석사학위 논문, 1996

[4] 이민구, “인터넷 유해정보 유입방지 방안에 관한 연구”, 아주대학교 산업대학원 컴퓨터공학과, 석사학위 논문, 1998

[5] 정희, “유해 정보 차단을 위한 검색 시스템의 설계와 구현”, 창원대학교 대학원 전자계산학과, 석사학위 논문, 1999

[6] 정명숙, “청소년을 위한 유해 웹 영상 차단 시스템의 구현”, 경상대학교 교육대학원 전산교육, 2000

[7] 정경수, “인터넷을 이용한 정보시스템의 전략적 활용”, 경북대학교 경영대학원, 1997

[8] Makoto Okada, Kazuaki Ando, Kazuhro Morita, Jun-ichi Aoe, “An Efficient Determination of Keywords for Compound Words”, Proceedings of 18th ICCPOL, Vol 1, pp317-320, March 1999.

[9] Kazuaki Ando, Toshiharu Kinoshita, Masami Shishibori, Jun-ichi Aoe, “An improvement of the Aho-Corasick machine”, International Journal of Information Sciences, Vol 3, pp139-151, 1998.

[10] Kazuaki Ando, Masao Fuketa, Masami Shishibori, Jun-ichi Aoe, “Dictionary Structure for Morphological Analysis of Oriental Languages”, Proceedings of 18th ICCPOL, Vol 1, pp533-538, March 1999.

[11] A. V. Aho, M. J. Corasick, “Efficient string matching: an aid to bibliographic search”, Comm. ACM, Vol.18, No.6, pp.333-340, 1975.

[12] 이진관, “테이블을 이용한 AC 기반의 키워드 검색 기법”, 군산대학교 컴퓨터정보공학과, 석사학위 논문, 2002