

표 8. 스팸 단어 목록

보도방	유혹	한방울	대박	조건	만남
오빠	성인	은밀	즐섹	미소녀	글래머
킹카	미씨	처자	파트너	봉지	폴타임
서양녀	대기	여대생	섹스	오랄	가능
만원	콜	화끈	클릭	사절	비밀
여학생	채팅	나이	사진	프로필	아이디
아뒤	사이트	후불	가입	현금	무료
입금	다운	바다이야기			

표 9. 수집한 스팸 댓글 200개에서 스팸 단어가 출현한 횟수

보도방	유혹	한방울	대박	조건	만남
3	4	3	6	25	47
오빠	성인	은밀	즐섹	미소녀	글래머
24	28	20	1	0	1
킹카	미씨	처자	파트너	봉지	폴타임
2	1	11	11	6	4
서양녀	대기	여대생	섹스	오랄	가능
4	6	5	0	0	63
만원	콜	화끈	클릭	사절	비밀
31	26	25	3	11	11
여학생	채팅	나이	사진	프로필	아이디
14	2	16	16	12	14
아뒤	사이트	후불	가입	현금	무료
6	18	11	29	8	22
입금	다운	바다이야기			
4	4	4			

2.5 알고리즘

본 시스템에서 사용하는 알고리즘은 스팸 댓글의 특성을 파라미터로 하여, 파라미터의 값을 기준으로 일정 값 이상을 가질 경우 스팸 댓글이라고 판단하는 것이다. 알고리즘에서 사용하는 파라미터는 앞에서 스팸 댓글의 특징으로 뽑은 4가지를 이용할 것이다. 즉, 1)특수문자, 2)url, 3)반복출현, 4)스팸 단어 이상 4가지이다. 알고리즘을 실행할 때 입력단위는 하나의 댓글 문치이다 댓글 문치라 함은 하나의 글에 달린 댓글들의 집합을 의미한다. 알고리즘의 출력은 입력된 댓글 문치에 대해서 각각의 댓글에 대한 판별 결과이다 댓글 문치가 입력 단위가 되는 이유는 여러 댓글들 중에서 동일한 내용의 댓글이 출현하는 지를 알아보기 위해서이다.

파라미터의 경우 각각의 파라미터마다 가중치를 달리 하였다. 예를 들어서 특수 문자의 경우는 정상적인 댓글에서도 이모티콘의 형태 등으로 사용될 가능성이 크다 따라서 특수 문자 각각에 대해서 높은 가중치를 줄 경우 판단 결과가 정확하지 않을 것이다. 반대로 하나의 댓글 문치 내에서 같은 내용으로 여러 번 나타난 댓글은 스팸이라고 판단 할 수 있으므로 이 경우에는 해당 파라미터의 가중치를 높게 줄 수 있다. 이처럼 파라미터의 가중치를 실험을 통해서 적절한 값으로 설정해 주어야 한다




그림 1. 알고리즘의 입력과 출력

알고리즘에서 파라미터의 가중치를 지정하는데 있어서 중요한 기준은 정상적인 댓글을 스팸 댓글로 판정하여 삭제하는 경우이다. 스팸 댓글을 정상 댓글이라고 판별한 경우도 문제이기는 하지만 이것은 알고리즘의 개선을 통해서 수정하거나 직접 삭제할 수 있지만 앞에서 언급한 경우처럼 정상 댓글을 스팸이라고 판단하여 삭제한 경우에는 유효한 정보의 손실을 의미하므로 심각한 문제를 초래할 수 있다. 따라서 파라미터의 가중치를 설정하는 과정에서는 이처럼 정상 댓글을 스팸 댓글로 판단하는 경우를 줄여 줄 수 있는 방향으로 접근하도록 해야 한다.

알고리즘 내부는 다음과 같이 작동한다




그림 2. 알고리즘 구조

3. 결 론

실험에서 사용한 데이터는 댓글 문치가 총 87개이며 포함된 댓글의 수는 모두 2911개이다. 전체 댓글 중에서 정상적인 댓글의 수는 1860개이며 스팸 댓글의 수는 1051개이다. 알고리즘을 적용하기 전에 전체 댓글에 대해서 각각 내용을 검토하여 직접 스팸 댓글과 정상 댓글로 구분하였다. 구분 기준은 처음에 언급했던 스팸 댓글의 정의에 따랐다. 파라미터에 사용된 가중치는 특수 문자에 대해서 1, url에 대해서는 3, 스팸 단어에 대해서는 5, 마지막으로 반복 출현된 댓글에는 20을 설정하였다. 그리고 파라미터 값의 총 합이 20이 넘으면 스팸으로 판단하였다. 그 결과 수집한 모든 댓글에 대해서 실험한 결과 98.11%의 정확도를 얻을 수 있었다. 단순한 방법이지만 수집한 댓글에 대해서는 매우 우수한 결과를 얻을 수 있었다.

앞으로 개선할 사항은 스팸 단어 사전의 활용 부분이다. 현재는 이미 입력된 단어를 기반으로 파라미터 값을 구하고 있지만 추후에는 스팸 댓글로 판별된 댓글의 내용을 분석하여 자동적으로 빈번히 출현한 단어에 대해서는 사전에 등록시키고, 기존에 등록된 단어라도 정상 댓글과 스팸 댓글을 판단하는 기준으로 부적합하다고 여겨지면 사전에서 제외시킬 필요가 있다. 또한 이것은 동일한 의미의 여러 형태의 단어에 대해서도 필요한 과정이다. 예를 들어서 “아르바이트”에 대해서 “알바”가 많이 사용되다가 “아르바”라는 형태로 많이 사용된다면 사전에 등록되는 단어도 변경될 필요가 있을 것이다. 또한 단어마다 가중치를 다르게 둘 수도 있다. 이를 위해서 댓글의 내용을 분석하고 특정 단어의 출현 빈도를 측정하는 과정이 필요하다.