creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학석사 학위논문

소셜 네트워크 서비스상에서 알림의 흥미도 예측을 통한 사용자의 효율적인 알림 탐색 지원

"Show me the funniest"

Predicting Interesting Notifications in Social Network Services for Efficient Notification Exploration

2019년 2월

서울대학교 대학원

컴퓨터공학부

김 이 은

소셜 네트워크 서비스상에서 알림의 흥미도 예측을 통한 사용자의 효율적인 알림 탐색 지원

"Show me the funniest"

Predicting Interesting Notifications in Social Network Services for Efficient Notification Exploration

지도 교수 서 진 욱

이 논문을 공학석사 학위논문으로 제출함

2018년 10월

서울대학교 대학원

컴퓨터공학부

김 이 은

김이은의 공학석사 학위논문을 인준함

2018년 12월

위 원 장 신영길 (인)

부위원장 서진욱 (인)

위 원 이제희 (인)

초록

여러 소셜 네트워크 서비스(SNS)에서 공통적으로 수신 시간 순으로 정렬된 알림 목록을 제공하여 사용자가 관심 있는 정보를 효율적으로 탐색할 수 있도록 지원하고 있다. 이 때, 알림 목록에 존재하는 수많은 알림에 대한 사용자의 관심도는 시간뿐만 아니라 발신자, 종류, 내용 등 다양한 요소에 의해서 결정된다. 그러나 대부분의 소셜 네트워크 서비스에서 알림 목록은 수신 시간 순서로만 정렬되어 제공되므로 사용자는 흥미로운 알림을 찾는 것에 어려움을 겪고 있다. 본 논문에서는 SNS 사용자들이 알림 목록에서 알림을 효율적으로 탐색할 수 있도록 돕기 위하여, 대표적인 SNS 중 하나인 Facebook 알림의 흥미도 점수를 예측하여 흥미도 점수가 높은 알림을 먼저 보여주는 알림 목록을 제안한다. 알림 흥미도 평가 실험을 통하여 1,988개 알림의 흥미도 데이터를 구축하고, 인간의 평가 기준을 모사하는 신경망 예측 모델을 구현했다. 선형 회귀 및 여러 구조의 신경망 예측 모델을 비교한 결과, 40개의 뉴런으로 구성된 1개의 은닉층을 가진 신경망 모델을 선택하였다. 해당 신경망 모델에 Adam 최적화 알고리즘을 적용하고 학습 속도를 0.001 로 설정한 후 2,000번의 학습을 반복한 결과, 실제 수집한 흥미도 점수에 대하여 스피어만 상관 계수 값은 0.679, 결정 계수 값은 0.453 로 최상의 예측 성능을 보였다. 사용자 실험 결과, 사용자들은 수신 시간 순 정렬 알림 목록보다 흥미도 점수 순 정렬 목록을 사용했을 때 더 효율적으로 흥미로운 알림을 찾을 수 있었고, 인터뷰를 통하여 흥미도 점수 순 정렬 알림 목록을 더 선호하는 것을 확인하였다.

주요어 : 소셜 네트워크 서비스, 알림, 예측 모델, 선형 회귀, 신경망

학 번 : 2017-24950

목 차

1. 서론 1

2. 관련 연구 5

3. 알림의 흥미도 평가 실험 10

3.1 실험 설계 10

3.1.1. 실험 개요 10

3.1.2. 실험 참여자 10

3.1.3. 특성 탐색 12

3.1.4. 특성 추출 16

3.1.5. 데이터 수집 18

3.2 예비 사용자 실험 20

3.2.1. 실험 결과 및 분석 20

4. 예측 모델 설계 24

4.1 예측 모델 선택 25

4.1.1. 성능 평가 지표 25

4.1.2. 예측 모델 비교 27

4.2 특성 중요도(Feature Importance) 31

5. 사용자 실험 33

5.1. 실험 설계 33

5.1.1. 실험 개요 33

5.1.2. 독립 변수 34

5.1.3. 종속 변수 35

5.1.4. 실험 참여자 35

5.2 실험 결과 37
5.2.1. 수행 시간 37
5.2.2. mAP 38
5.2.3. 흥미도 점수 39
5.2.4. 주관 평가 점수 39
6. 논의 43
7. 한계 및 향후 연구 46
8. 결론 48
참고문헌 49
ABSTRACT 51

표 목차

표 1. 발신자와 관련된 특성 13
표 2. 알림 종류와 관련된 특성(1). 14
표 3. 알림 종류와 관련된 특성(2). 15
표 4. 알림 내용과 관련된 특성 16
표 5. 추출하기로 선정된 특성. 17
표 6. 예비 사용자 실험에서 전체 알림의 흥미도 점수의 평균과 친밀도 점수가 3인 알림의 흥미도 점수의 평균 22
표 7. 예비 사용자 실험에서 전체 알림의 흥미도 점수의 평균과 직접적인 사용자 언급이 있는 알림의 흥미도 점수의 평균 23
표 8. 신경망의 인자. 25
표 9. [11]에서 제시한 스피어만 상관 계수의 범위에 따른 해석. 26
표 10. [13]에서 제시한 스피어만 상관 계수의 범위에 따른 해석. 26
표 11. [14]에서 제시한 스피어만 상관 계수의 범위에 따른 해석. 27
표 12. 선형 회귀 모델 성능. 28
표 13. 은닉층의 뉴런 개수에 따른 예측 성능 결과 30
표 14. 선형 회귀 모델의 특성 중요도 분석 결과. 32

그림 목차

그림 1. FACEBOOK 알림 목록[17] 2
그림 2. FACEBOOK 알림 설정[17] 3
그림 3. CONTENT 카테고리의 각 이벤트 타입에 대한 유의도 검증(SIGNIFICANCE TEST) 결과 8
그림 4. 이벤트 타입 추천 알고리즘. 8
그림 5. 알림 확인 시 중요하게 생각하는 요소(복수 응답, N=23). 11
그림 6. FACEBOOK 친구 목록. 19
그림 7. FACEBOOK 사용자가 가입한 그룹 목록. 19
그림 8. 신경망 구조. 24
그림 9. 학습 횟수(1,000-10,000)와 학습 속도(0.01, 0.001)에 따른 스피어만 상관 계수 결과 29
그림 10. 학습 횟수(1,000-10,000)와 학습 속도(0.01, 0.001)에 따른 결정 계수 결과. 29
그림 11. 사용자 실험 환경. 34
그림 12. 시간 정렬(SD=1.25)과 흥미도 정렬(SD=1.13)에 따른 평균 수행 시간(S) 37
그림 13. 시간 정렬과 흥미도 정렬에 따른 평균 MAP 38
그림 14. 시간 정렬과 흥미도 정렬에 따른 평균 흥미도 점수. 39
그림 15. 시간 정렬과 흥미도 정렬에 따른 질문 1의 답변 점수 . 40
그림 16. 시간 정렬과 흥미도 정렬에 따른 질문 2의 답변 점수 . 41
그림 17. 시간 정렬과 흥미도 정렬에 따른 질문 3의 답변 점수 . 42

1. 서론

최근, 소셜 네트워크 서비스(Social Network Services, 이하 SNS)를 활발하게 사용하는 사용자들이 점점 증가하여 대표적인 SNS인 페이스북, 트위터, 인스타그램은 수백만의 사용자를 보유하고 있다[1]. SNS의 대표적인 기능 중 하나인 알림 기능은 사용자가 필요로 하거나 관심이 있는 정보를 효율적으로 얻을 수 있고, 친교 활동을 원활하게 진행할 수 있도록 도움을 준다(그림 1). 본 논문에서는 SNS 사용자들이 알림 목록에서 알림을 효율적으로 탐색할 수 있도록 돕기 위해, 대표적인 SNS중 하나인 Facebook 알림의 흥미도 점수를 예측하여 흥미도 점수가 높은 알림을 먼저 보여주는 알림 목록을 제안한다. Facebook 사용자 23명의 1,988개 알림에 대한 흥미도 데이터를 학습시켜 알림의 흥미도 예측 모델을 설계하였다. 그 결과, 스피어만 상관 계수 값이 0.679($p < .0001$), 결정 계수 값은 0.453의 예측 성능을 보였다. 기존의 시간 순으로 정렬된 알림 목록과 비교하기 위해 사용자 실험을 한 결과, 흥미도 순서 알림 목록을 사용 했을 때 사용자들이 유의미하게 더 흥미로운 알림을 찾을 수 있었으며, 탐색 시간, mAP(Mean Average Precision), 주관 평가 결과에서도 개선이 있었다.

그림 1. Facebook 알림 목록[17].

Facebook은 그림 2와 같이 특정 알림 종류(생일, 과거의 오늘, 태그, 그룹 활동 등), 사용자 본인과 관련된 활동 등에 대해서 사용자가 선택적으로 알림을 수신할 수 있도록 알림 설정 기능을 제공한다. Facebook 상의 이러한 알림 설정 기준에 대하여 23명의 Facebook 사용자들을 대상으로 설문 조사를 진행한 결과, Facebook에서 제공하는 기능 외에도 사용자들이 알림을 확인할 때 중요하게 생각하는 요소로 발신자와의 개인적인 친밀도, 알림 내용, 추가적인 알림 기준(댓글, 좋아요의 개수) 등이 있음을 확인하였다. 해당 설문 조사를 통해 사용자가 수신하기로 설정한 알림일지라도 다양한 수준의 중요도 및 흥미도를 가질 수 있다는 사실을 확인하였다. 예를 들어, “A님이 회원님의 게시물에 댓글을 달았습니다.”라는 제목의 알림과 “A님이 회원님에게 페이지 좋아요를 요청했습니다.”라는 제목의 알림이 동일한 시간에 동일한 동일한 발신자로부터 왔다고 하더라도, 알림의 유형이 다르기 때문에 사용자에게 흥미로운 정도는 다를 수 있다. 또한, Facebook 사용자들은 알림 목록에서 다양한 방식으로 알림을 탐색한다. 일반적으로 알림 목록의 가장 상위권의 알림부터 순서대로 모든 알림을

읽는 방식이 있다. 이외에도 흥미로워 보이는 알림 위주로만 읽는 사용자들도 있다. 이 경우에도 기존의 방법대로 시간 순서대로 보여주는 것 보다 흥미도를 예측하여 알림 목록을 제공하는 것이 보다 효과적일 것이다.

그림 2. Facebook 알림 설정[17].

현재 Facebook을 포함한 대부분의 SNS 알림 목록은 알림을 수신한 시간 순서로 정렬하여 제공한다. 그러나 앞서 언급한 바와 같이 알림의 흥미로운 정도는 시간뿐만 아니라 발신자, 종류, 내용 등 다양한 요소에 의해서 결정된다. 그러므로 수신 시간 순서로만 정렬한 알림 목록에서 사용자가 흥미로운 알림을 찾는 것은 쉽지 않다. 알림과 관련된 기존의 많은 연구들은 사용자의 현재 상황을 고려하여 사용자를 방해하지 않으면서 사용자가 흥미롭고 중요하다고 생각할만한 알림 내용에 대해서만 알림을 주는 방식에 대해 연구해왔다[4][5][7][10]. 그러나 대부분의 선행 연구는 사용자가 모바일을 사용하는 환경에서 다른

작업(업무, 휴식, 이동 등)를 하고 있는 상황을 전제로 하였으며, 알림에 대한 사용자의 행동을 예측하는 문제를 분류 문제(Classification Problem)로 다루어 사용자에게 알림을 보여주는 것과 보여주지 않는 두 가지의 선택지로 나누는 방식을 택하였다. 그러나 사용자에게 보여주기로 분류된 알림 사이에서도 흥미도가 다를 수 있으며, SNS상의 수많은 알림 정보로 구성된 알림 목록에서 사용자가 관심있는 알림을 찾을 때 겪는 어려움에 대한 연구는 거의 이루어지지 않았다.

본 논문의 2절에서는 모바일 알림 관리 시스템과 중요도 기반 정렬 목록과 관련된 선행 연구에 대해 살펴보았고, 3절에서는 사용자들의 흥미도 평가 데이터를 수집하기 위해 진행한 실험 과정 및 결과에 대한 내용을 정리하였다. 그리고 4절에서는 3절의 데이터를 학습하는 흥미도 예측 모델을 제안하였으며, 마지막으로 5절에서는 본 연구에서 제안한 흥미도 예측 모델에 대한 검증을 하기 위한 사용자 실험에 대해 논의하였다.

2. 관련 연구

본 절에서는 모바일 환경에서 사용자에게 방해가 될 수 있는 알림의 문제점을 다룬 선행 연구와 SNS 알림이나 이메일 등의 특정 알림 종류의 특성에 대해 탐색 및 분석한 선행 연구를 살펴보고, 이들 연구에서 해당 문제를 해결하기 위해 사용한 방식의 한계점과 다루지 않은 문제점에 대하여 논의한다.

많은 선행 연구들이 모바일 환경에서의 알림으로 인한 사용자 방해에 대한 주제를 다룬다. 이는 대부분의 사용자가 모바일을 항상 몸에 지니고 있으며, 알림으로 인해 사용자가 현재 수행 중인 작업에 방해가 되는 상황이 흔하기 때문이다[8]. 대부분의 사용자들은 자신과 관련이 없거나 받기를 원하지 않는 알림이 온 경우, 현재 진행 중인 작업을 크게 방해받거나 귀찮음을 느끼게 되고 이는 알림을 보낸 해당 어플리케이션을 삭제하는 행동까지 이어진다[1].

모바일 알림으로 인한 방해도(Interruptibility) 문제를 해결하기 위해 선행 연구들은 다양한 방식을 시도하였다. 일반적인 모바일 알림의 방해도를 관리하는 시스템으로, Mehrotra et al.은[5] 알림에 대한 사용자의 선호도(Preference)를 학습하여 알림의 방해도를 관리하는 솔루션인 PrefMiner를 제안하였다. 이 시스템은 알림과 사용자의 상호작용 데이터를 기반으로 하여 연관 법칙(Association Rule)을 자동으로 추출한다. PrefMiner를 통해서 사용자는 직접 룰을

생성하거나 삭제하는 일에 관여할 수 있다. 실제로 15일간 앱을 배포하여 16명의 사용자들의 사용 결과를 분석한 결과, 총 179개의 룰을 생성하였고 이 중 56.98%의 룰을 사용자가 받아들였다. 선택된 룰에 대해서는 Precision은 100%, Recall은 45.81%의 결과를 보였다. 그러나 이 연구는 단지 사용자가 알림을 받을 것인지 받지 않을 것인지에 대해서만 분류를 한다는 점에서 한계가 있다.

일반적인 알림 외에도 Pielot et al.은[7] SMS와 WhatsApp 등의 앱을 통해 오는 모바일 인스턴스 메시지 알림에 대한 사용자들의 관심도를 예측하기 위한 연구를 진행하였고, 메시지와 관련된 다양한 특성들을 탐색 및 분석하였다. 그리고 해당 메시지 알림에 대한 사용자의 관심도를 두 종류의 클래스(높음과 낮음)로 분류하였다. 알림의 클래스를 예측하기 위하여 SVM(Support Vector Machine), Random Decision Tree, Random Forest 방식의 결과를 비교하였고, 정확도가 70.6%로 가장 좋은 성능을 보인 Random Forest를 택하였다. 가장 예측 성능이 좋았던 특성은 총 7가지로, 마지막으로 스크린이 켜진 시간, 마지막으로 스크린이 꺼진 시간, 마지막으로 스크린을 본 시간, 현재 시각, 알림 모드, 스크린을 마지막으로 덮은 이후로 걸린 시간, 현재 스크린이 켜져 있는지 여부가 있다. 그러나 이 연구도 위의 PrefMiner와 마찬가지로 알림을 두 개의 유형(관심도 높음과 낮음)으로만 분류했다는 한계점을 가진다.

Yuan et al.[10] 또한 사용자가 알림으로 인한 방해를 최소한으로 받기 위한 연구를 다루었다. 이 연구는 알림의 종류나 내용 데이터를 기반으로 방해도를 예측하는 기존의 연구와 다르게, 사용자의 모바일 사용 패턴이나 개인적인 특성(Personality Trait)를 학습하여 알림의

방해도를 예측하는 모델을 제안하였고 예측 모델을 2단계의 계층 구조로 설계하였다. 첫 번째 단계에서는 기존 연구들과 유사하게 사용자의 개인적인 특성과 모바일 센서 데이터를 기반으로 사용자가 알림을 읽을지 읽지 않을지를 예측한다. 그리고 사용자가 읽는다는 예측 결과가 나오면, 두 번째 단계에서 사용자의 현재 상황의 정보를 기반으로 알림의 방해 정도(Interruptibility Intensity)를 점수로 예측한다. 첫 번째 단계에서 선택한 모델은 Decision Tree와 SVM이 정확도 75%로 거의 유사한 성능을 보였으며, 두 번째 단계에서는 AR(Additive Regression)모델을 사용하여 66.2%의 정확도를 보였다.

Bouraga et al.은[2] SNS 알림을 구성하는 다양한 특성들을 탐색하고, 각 특성이 알림의 중요도에 영향을 미치는 정도를 알아보기 위하여 설문을 진행하였다. SNS 알림을 구성하는 특성들을 총 6가지의 그룹으로 나누었는데, 종류로는 Profile, Recommendation, Content(그림 3), Connection, Link, Privacy가 있다. 총 450명의 대학생을 대상으로 설문을 진행함으로써 각 종류에 속하는 특성이 알림의 중요도에 유의미하게 영향을 미치는지를 살펴보았다. 각 이벤트 타입에 따라 사용자에게 설문을 진행한 결과, 중요도 순서를 매긴 결과를 기반으로 하여 그림 4와 같이 이벤트 타입을 추천하는 예측 모델을 도출하였다. 그러나 이 또한 분류 문제를 해결하기 위한 결정 트리 학습법(Decision Tree Learning)을 예측 모델로 사용하였으며, 동일한 카테고리에 속하는 이벤트 타입은 모두 동일한 방식으로 처리된다는 한계점이 있다.

Event type	Agree	Neutral	Disagree	Chi square	*P* value	Decision H_0 ($\alpha = 5$ %)
Short text	96	36	15	72.1224	<2.2e−16	Reject
Long text	33	52	62	8.8571	0.01193	Reject
Comment on profile information	24	65	58	19.6327	5.455e−05	Reject
Comment on status	55	58	33	7.6575	0.02174	Reject
Comment on media	80	44	23	33.9184	4.312e−08	Reject
Comment on relationship status	44	48	55	1.2653	0.5312	Do not reject
Like status	39	55	53	3.102	0.212	Do not reject
Like media	55	51	41	2.1224	0.346	Do not reject
Share status	46	55	46	1.102	0.5764	Do not reject
Share media	68	43	36	11.551	0.003103	Reject
Tag friends on status	57	61	28	13.3288	0.001276	Reject
Tag friends on media	73	51	23	25.6327	2.716e−06	Reject

그림 3. Content 카테고리의 각 이벤트 타입에 대한 유의도 검증(Significance Test) 결과.

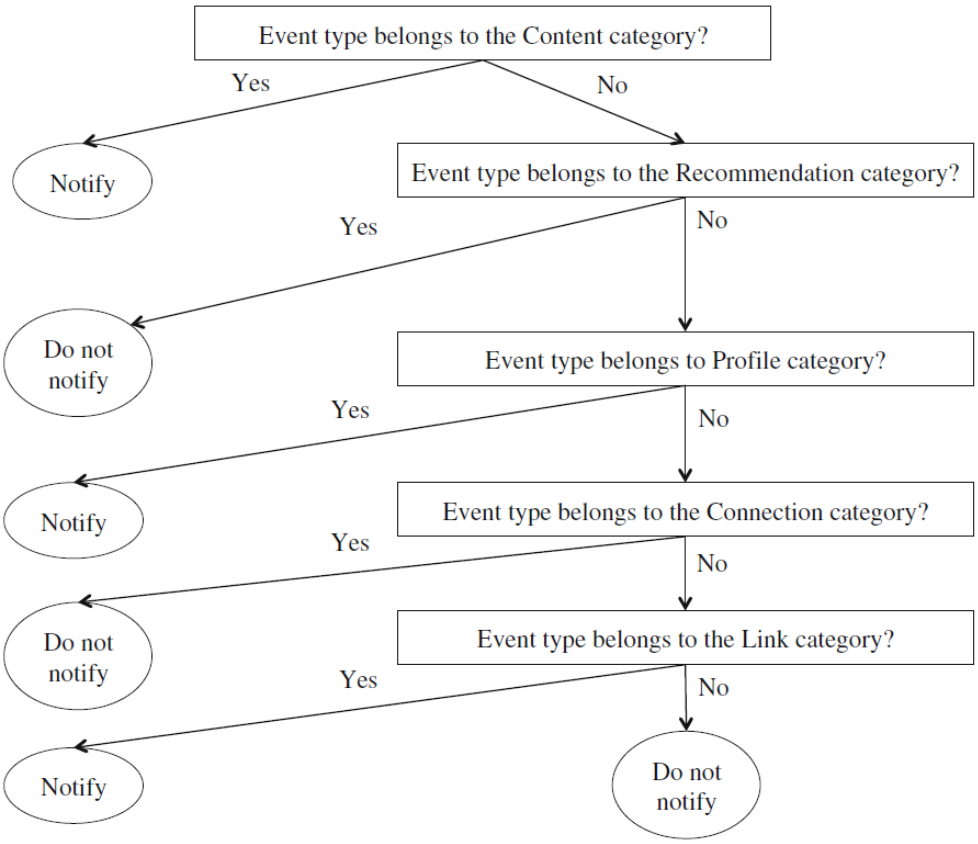

그림 4. 이벤트 타입 추천 알고리즘.

이 외에도 구글 Gmail에서는 메일을 구성하는 여러 요소들을 고려하여 자동으로 이메일을 중요 혹은 중요하지 않음으로 표시하는 기능을 제공한다[16]. 이 때 고려하는 요인으로는, 내가 이메일을 보내는 사용자 및 사용자에게 이메일을 보내는 빈도, 내가 여는 이메일, 내가 답장하는 이메일, 내가 일반적으로 읽은 이메일에 사용된 키워드, 내가 별표 표시하거나 보관처리하거나 삭제하는 이메일이 있다. 중요하다고 판단되는 이메일은 중요도가 높다고 표시함으로써 사용자가 많은 이메일이 쌓여있는 이메일 목록을 탐색할 때, 흥미롭거나 중요한 이메일을 놓치지 않고 빠르게 확인할 수 있도록 도움을 준다. 이처럼 본 논문에서는 SNS 알림의 흥미도를 예측하고 기존의 목록을 흥미도 순서로 재배열하여 사용자에게 제공하고 유용성을 검증하고자 한다.

3. 알림의 흥미도 평가 실험

Facebook상의 알림에 대한 사용자들의 흥미도 점수를 예측하는 모델에 사용될 학습 데이터를 수집하기 위해서 Facebook 사용자를 대상으로 실제 알림에 대해 흥미도를 평가하는 실험을 진행하였다. 본 실험에서는 사용자가 수신한 알림에 대한 흥미도 평가 점수와 해당 알림을 구성하는 특성의 값을 수집하였다.

3.1 실험 설계

3.1.1. 실험 개요

참여자는 1년 이내에 자신에게 도착한 알림에 대해서 실제로 알림을 선택하여 내용을 확인한 후에 흥미도 점수를 평가하는 태스크를 수행하였다. 흥미도 점수는 총 5단계로, 1(흥미롭지 않다) – 2(거의 흥미롭지 않다) – 3(보통이다) – 4(조금 흥미롭다) – 5(매우 흥미롭다)로 나누었다.

3.1.2. 실험 참여자

총 23명 (남자 16명, 여자 7명)이 참여하였으며, 수집한 Facebook 알림 데이터는 총 1988개이다. Facebook 사용자를 대상으로 실제 사용자의 알림 데이터를 수집하기 위한 실험이므로, 실험 참여자 선정 기준은 1) Facebook을 최근 한 달 이내에 한번이라도 사용한 적이 있는 만 18세 이상의 성인 2) Facebook에서 1년 이내에 도착한 알림의

개수가 최소 50개 이상인 사람으로 정하였다. 실험 참여자들의 Facebook 사용 패턴에 대한 설문을 진행한 결과, Facebook을 한 달에 한두 번 사용하는 참여자는 3명, 일주일에 한두 번 사용하는 참여자는 5명, 하루에 1-3번 사용하는 참여자는 9명, 하루에 5번 이상 사용한다고 응답한 참여자는 6명이었다. 또한 실험 참여자들이 Facebook 알림 목록에서 알림을 확인할 때 중요하게 생각하는 요소에 대한 설문 조사 결과는 그림 5와 같다. 23명의 참여자 중 절반이 넘는 사용자들이 알림의 발신자와 내용을 중요하게 생각한다고 응답하였다.

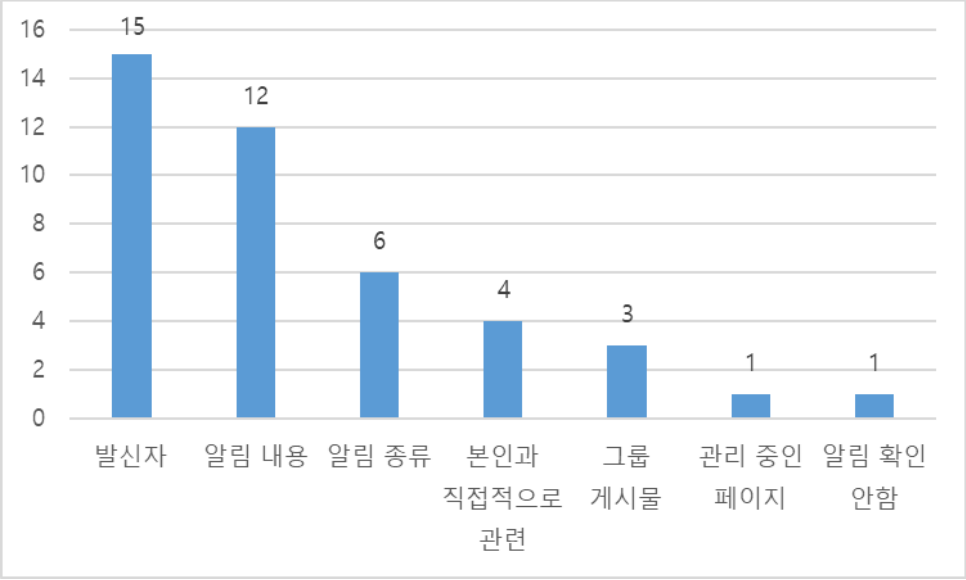

그림 5. 알림 확인 시 중요하게 생각하는 요소(복수 응답, N=23).

3.1.3. 특성 탐색

SNS상의 알림을 구성하는 주요한 특성들을 선별하기에 앞서 관련 연구에서 탐색한 특성들과 알림 데이터로부터 유의미할 가능성이 있는 특성들을 정리하였다. 본 연구에서는 게시물 내용, 댓글 내용 등 알림이 담고 있는 실제 내용과 관련된 직접적인 정보를 포함하는 것이 성능 향상에는 큰 도움이 될 수 있다고 생각하지만, 실험 참여자들의 사생활 침해 문제로 인해 해당 정보와 관련된 특성은 배제하였다.

Bouraga et al.은[11] 설문을 통해 각 특성이 알림의 중요도에 어느 정도 영향을 미치는지 알아보았다. 해당 연구에서 다룬 특성들과 본 연구에서 수집한 Facebook 알림 540개로부터 사용 가능한 특성들을 탐색한 결과, 총 45개의 특성을 얻고 이를 4개의 종류로 체계화할 수 있었다. 4개의 특성 종류는 1) 발신자와 관련된 정보로 구성된 특성(13개, 표1), 2) 알림의 종류와 관련된 특성(20개, 표2), 3) 알림의 메타데이터(Metadata) 정보로 구성된 특성(2개, 표3), 4) 알림의 내용과 관련된 특성(10개, 표4)으로 나누었다.

카테고리	특성		값
발신자	사용자	관계	본인 / 일반친구 / 친한 친구 /다른 사용자
		성별	여/남
		발신자로부터 받은 알림 개수	0 ~ 전체 알림 개수
		발신자와 알고 지낸 기간	1 ~ Facebook 가입한 후 기간
		발신자와 함께 아는 친구 수	0 ~ 전체 친구 수
		사용자 친구 수	친구 수
	그룹	가입 여부	가입/비가입
		즐겨찾기 설정 여부	즐겨찾는 그룹/ 일반 그룹
		그룹 가입 기간	1 ~ Facebook 가입한 후 기간
		그룹 멤버의 수	그룹 멤버 전체 수
		공개 그룹 여부	공개/비공개
	페이지	관계	나의 페이지/ 즐겨찾는 페이지/다른 페이지
		시스템	

표 1. 발신자와 관련된 특성.

카테고리	특성	
알림 종류	사용자	프로필 추가 또는 변경
		포스트
		상태 업데이트
		댓글
		좋아요
		태그
		라이브 비디오
		페이지 좋아요 요청
		그룹 가입 요청
		이벤트 참여 요청

표 2. 알림 종류와 관련된 특성(1).

카테고리	특성	
알림 종류	사용자	생일 알림
	그룹	그룹 가입 요청 허용
		그룹 가입 요청
		그룹 초대
		그룹 이름 변경
	페이지	이벤트 초대
	시스템	친구 추천
		비디오 추천
		내 페이지 관리
		내 페이지 현황 알림

표 3. 알림 종류와 관련된 특성(2).

카테고리	특성
알림의 메타데이터	알림 확인 여부
	도착 시간
알림 내용	미디어(텍스트/사진/비디오)
	텍스트 길이
	사진 개수
	비디오 개수
	태그된 사람 존재 여부
	장소 표시 여부
	이모티콘 사용 여부
	좋아요 개수
	공유 개수
	댓글 개수

표 4. 알림 내용과 관련된 특성.

3.1.4. 특성 추출

3.1.3에서 탐색한 특성들로부터 다음과 같은 기준을 사용하여 추출하고자 하는 특성들을 선정하였다. 1)실제로 Facebook 상에서 추출이 가능한 특성이여야 한다. 2) 기존 연구에서 알림의 중요도에 유의미하게 영향을 미친다고 판단이 된 특성이여야 한다. 3) 특성 탐색을 위해 수집한 알림 540개에 한 번 이상이라도 포함된 특성이여야 한다. 이 결과 표 5와 같이 총 13개의 특성을 추출하기로 선정하였다.

No	특성 / 특징	설명
01	ArrivalTime 범주형	알림을 수신한 시각 범위
02	Sender 범주형	알림의 발신자(사용자, 그룹, 페이지, 시스템)
03	Relationship 범주형	알림의 발신자와의 관계(친구, 친한 친구, 좋아하는 페이지, 나의 페이지 등)
04	TypeofNotification 범주형	알림의 타입(생일, 친구 추천, 게시물 작성, 태그 등)
05	MutualFriends 양적	알림의 발신자가 사용자일 때, 해당 사용자와의 함께 아는 친구 수
06	GroupAttribute 참/거짓	알림의 발신자가 그룹인 경우 공개 그룹 여부
07	Media 범주형	알림의 외부 특성(텍스트, 사진, 비디오)
08	NumberofLikes 양적	알림이 게시물인 경우 해당 게시물의 좋아요 개수
09	TextLength 양적	텍스트로 구성된 알림의 경우 텍스트의 길이
10	NumberofPhoto 양적	사진으로 구성된 알림인 경우 사진의 개수
11	NumberofVideo 양적	비디오로 구성된 알림인 경우 비디오의 개수
12	IncludingMyself 참/거짓	알림이 사용자와 직접적인 관련이 있는지 여부
13	Intimacy 양적	알림의 발신자가 사용자일 때, 해당 사용자와의 친밀도

표 5. 추출하기로 선정된 특성.

3.1.5. 데이터 수집

흥미도 예측 모델을 학습시키기 위하여 흥미도 평가 실험에서 흥미도 데이터를 수집할 때 목표 개수는 실험 기간을 고려하여 약 2,000개로 설정하였고, 한 참여자 당 최소 50개에서 최대 150개의 알림을 평가하도록 했다. 이는 본 연구와 유사한 관련 연구를 근거로 산출된 숫자로, [10]에서는 33명의 사용자를 대상으로 2804개의 알림 데이터를 수집하였고, [7]에서는 사용자 실험 단계에서 총 24명의 사용자를 대상으로 6423개의 알림 데이터를 수집하였다.

수집 데이터로 참여자들의 알림 목록(그림 1), 친구 목록(그림 6), 가입한 그룹 목록(그림 7)으로부터 표 5에서 나온 특성들을 추출하였다. 데이터 수집 방식은 Facebook에서 제공하는 API를 사용하는 방식과 AJAX(Asynchronous Javascript and XML)를 사용하여 브라우저 요청을 통해 필요한 데이터를 가져오는 방식 중 전자의 방식은 특성 추출에 필요한 모든 데이터를 가져오는 것이 가능하지 않았으므로 후자를 택하였다. 또한, 데이터 수집 과정에서 사용자들의 개인적인 알림, 친구, 그룹에 대한 정보들이 노출될 수 있는 위험성이 있다. 그러므로 본 사용자 실험에서는 알림을 구성하는 특성 값들을 추출하고 난 후에는 실제 데이터 값은 모두 익명화하거나 버리는 방식을 택하였다.

그림 6. Facebook 친구 목록.

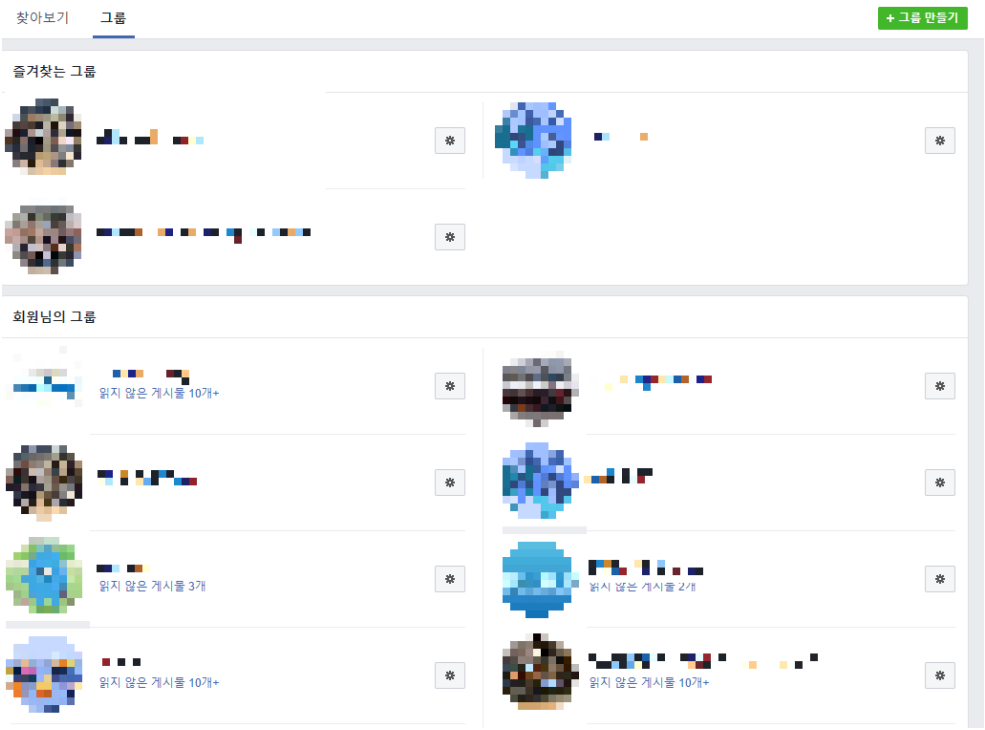

그림 7. Facebook 사용자가 가입한 그룹 목록.

3.2 예비 사용자 실험

본 사용자 실험을 진행하기에 앞서 데이터 수집의 가능성을 확인하고 개선점을 찾기 위하여 예비 사용자 실험을 진행하였다. 총 3명이 참여하였으며, 190개의 알림을 수집하였다. 참여자 전원 평소 Facebook을 일주일에 2-3번 이상 사용한다고 응답하였다.

3.2.1. 실험 결과 및 분석

- **한 참여자가 평가할 알림 데이터 개수.**

  실험 계획 단계에서 데이터 수집 시 한 참가자로부터 수집할 알림 데이터 개수의 목표는 50개로 설정하였다. 그러나 예비 사용자 실험을 진행한 결과, 3명의 참여자 모두 흥미도 평가 시 소요 시간이 20-30분 정도로 평가 과정이 빠르게 진행되는 것을 확인할 수 있었다. 흥미도 예측 모델을 정확하게 구축하기 위하여 최대한 많은 데이터를 수집하고자, 본 흥미도 평가 실험에서는 한 참여자 당 최대로 수집하는 알림 개수의 기준을 100-150개로 수정하였다.

- **일관적이지 않은 알림 형식.**

  2번 참여자의 페이지와 관련된 알림 데이터에서 알림 형식이 일관적이지 않음을 확인할 수 있었다. 알림의 제목은 “A님이 사진에 공감하였습니다.” 로, 해당 알림 제목만 보면 사용자가 자신의 타임라인에 올린 사진에 대한 알림으로 오해할 가능성이 있으나, 실제로 이 알림은 사용자가 운영하는 페이지에 대한 알림이다. 이는 본 연구에서 사용한 AJAX를 통한 크롤링의 한계상 분류하기가 쉽지 않았으므로 본 흥미도 평가 실험에서는

페이지와 관련된 알림 데이터는 모두 수집하지 않았다.

- **실험 과정에서 흥미도 평가 기준의 변화.**

  참여자는 흥미도 평가 실험에서 알림에 대한 흥미도 점수를 평가하는 태스크를 수행한다. 참여자들의 흥미도 평가 결과, 실험 초반부에 사용하는 흥미도 평가 기준과 실험 후반부에 사용하는 흥미도 평가 기준이 시간이 지남에 따라 변하는 가능성을 고려할 필요가 있음을 확인하였다. 본 흥미도 평가 실험에서는 참여자들에게 사전에 알리지 않고 흥미도 평가를 알림 목록의 가장 위 알림부터 진행하기로 했다. 평가를 완료하면, 첫 번째로 평가한 흥미도 점수를 가린 채로 두 번째 흥미도 평가를 수행하도록 진행했다. 최종적으로 알림의 흥미도 점수는 첫 번째와 두 번째 흥미도 점수를 평균을 낸 점수로 사용하였다.

- **새로운 특성의 추가 가능성 발견.**

  - **친밀도.**

    인터뷰 과정에서 3명의 참여자 모두 알림의 흥미도를 평가할 때, 알림을 보낸 사람과의 개인적인 친밀도가 영향을 주었다고 응답하였다. 이러한 경향을 반영하여 Facebook에서는 친구들과의 관계를 정의할 수 있는 기능을 제공한다. 기본적으로는 일반적인 설정인 아는 사람과 친한 친구로 나뉘어져 있다. 그러나 3명의 사용자 모두 해당 기능을 사용하지 않으며, 추후에 본 흥미도 평가 실험에서도 23명 중 20명이 해당 기능을 사용하지 않음을 확인하였다. 인터뷰 결과를 기반으로 친밀도 특성은 알림의 흥미도 점수에 직접적인 영향

을 줄 수 있는 요소라 추측되어 이는 본 흥미도 평가 실험에서 추가하고 참여자에게 따로 응답을 받도록 수정하였다. 응답은 “친하지 않다(1) – 친하다(2) – 매우 친하다(3)”로 총 3 단계로 나누었다. 3명의 참여자의 데이터를 기반으로 표 6과 같은 결과를 발견하였다. 세 참여자 모두 전체 알림 흥미도 점수를 평균한 결과에 비해 매우 친하다고 평가한 발신자가 보낸 알림의 흥미도 점수 평균이 높은 것을 확인하였다. 실제로 친밀도가 알림의 흥미도 점수에 유의미한 영향을 주는지 4.2절에서 확인하였다.

	참여자 1	참여자 2	참여자 3
전체 알림 흥미도 점수 평균	2.484	2.77	2.92
친밀도=3인 알림 흥미도 점수 평균	4.583	3.826	3.5

표 6. 예비 사용자 실험에서 전체 알림의 흥미도 점수의 평균과 친밀도 점수가 3인 알림의 흥미도 점수의 평균.

- **직접적인 사용자 언급 여부.**

인터뷰 과정에서 2번 참여자는 자신이 “직접적으로 언급이 된 알림의 경우에는 흥미도 점수를 높게 평가하였다.”라고 응답하였다. 직접적으로 사용자가 언급된 알림의 대표적인 예시로는 “A님이 회원님의 댓글에 답글을 남겼습니다.”나 “A님이 회원님의 게시물을 좋아합니다” 등이 있다. 인터뷰

결과, 본 요소가 알림의 흥미도에 영향을 줄 수 있는 요소라 추측되어 본 흥미도 평가 실험에서는 직접적인 사용자 언급 여부에 대한 특성을 추가하였다.

	참여자 1	참여자 2	참여자 3
전체 알림 흥미도 점수 평균	2.484	2.77	2.92
직접적인 사용자 언급이 있는 알림 흥미도 점수 평균	3.786	3.563	3.37

표 7. 예비 사용자 실험에서 전체 알림의 흥미도 점수의 평균과 직접적인 사용자 언급이 있는 알림의 흥미도 점수의 평균.

4. 예측 모델 설계

본 연구에서는 앞선 흥미도 평가 실험을 통해 수집한 Facebook 알림과 알림에 대한 흥미도 데이터를 입력 데이터로 사용하여 알림의 흥미도를 예측하는 모델을 구현하였다(그림 8). 최종적으로 1개의 은닉층을 가진 신경망을 구성하였으며, 입력 데이터에 대해서 Facebook 알림의 흥미도 점수를 예측하였다. 은닉층과 뉴런의 수는 다양한 조합을 시도한 후 성능 비교를 통하여 결정하였으며 학습을 위해 사용한 신경망의 각종 인자는 표 8과 같다.

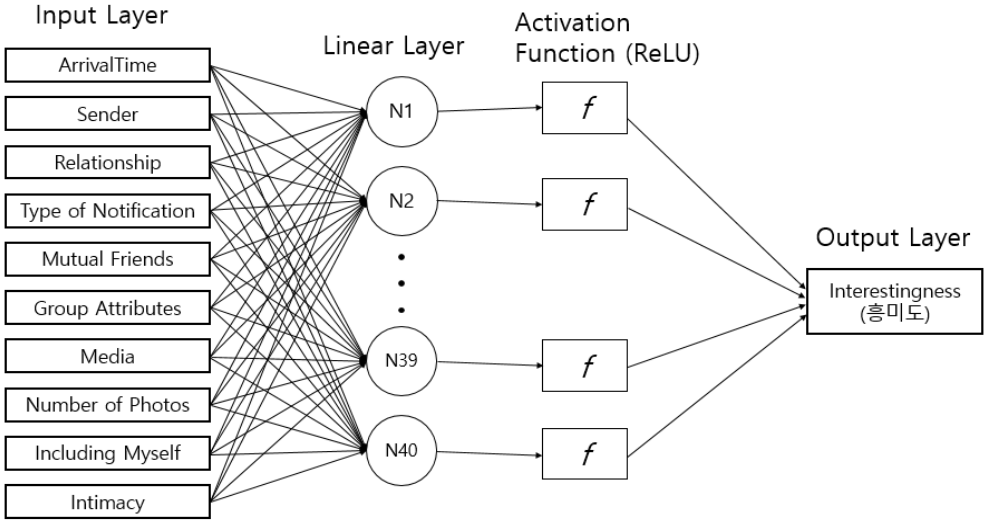

그림 8. 신경망 구조.

	신경망(NN)
은닉층	1 (뉴런 수 : 40)
입력 데이터	알림 구성하는 13종류의 특성 (36 Dimension)
활성 함수	ReLU(Rectifier)
손실 함수	MSE(Mean Squared Error)
트레이닝 셋	1,988
학습 횟수	2,000
학습 속도	0.001
최적화 알고리즘	Adam Optimizer
테스트 셋	397 (5-fold 교차 검증)

표 8. 신경망의 인자.

4.1 예측 모델 선택

4.1.1. 성능 평가 지표

성능 평가 지표로는 스피어만 상관 계수(Spearman's Rank Correlation Coefficient)와 결정 계수(Coefficient of Determination)를 사용하였다.

- 스피어만 상관 계수

  스피어만 상관 계수는 최소 -1, 최대 1의 값을 가진다. 이 때 값의 범위에 따라 두 변수간의 관계를 해석하는 방식이 달라진다. 이에 관련해서 통계학 분야에서 해석 기준을 제시한

여러 선행 연구가 있다. 표 9, 10, 11에 통계값의 범위에 따라 해석 기준이 제시되어 있다[11][13][14].

값	해석
.70 or higher	Very strong association
.50 ~ .69	Substantial association
.30 ~ .49	Moderate association
.10 ~ .29	Low association
.01 ~ .09	Negligible association

표 9. [11]에서 제시한 스피어만 상관 계수의 범위에 따른 해석.

값	해석
.90 ~ 1	Very high correlation
.70 ~ .90	High correlation
.50 ~ .70	Moderate correlation
.30 ~ .50	Low correlation
.00 ~ .30	Little if any correlation

표 10. [13]에서 제시한 스피어만 상관 계수의 범위에 따른 해석.

값	해석
.90 ~ 1	Perfect
.70 ~ .90	Very high
.50 ~ .70	High
.30 ~ .50	Moderate

.10 ~ .30	Low
.00 ~ .10	Practically zero

표 11. [14]에서 제시한 스피어만 상관 계수의 범위에 따른 해석.

- 결정 계수

  예측한 흥미도 점수와 실제 흥미도 점수 간의 유사도를 측정하기 위해 결정 계수를 이용하였다. 결정 계수는 두 변수 간의 설명력이 최대일 때 1이 되고, 최소일 때 0이 된다.

4.1.2. 예측 모델 비교

흥미도 점수 예측 문제를 해결하기 위해 본 연구에서는 잘 알려진 회귀(Regression) 모델인 선형 회귀(Linear Regression)와 신경망(Neural Network)을 평가하였다. 선형 회귀 모델은 베이스라인으로 삼았으며, 모든 평가에서 전체 데이터를 5개의 뭉치로 나누고 이중 4개의 뭉치를 학습 데이터로, 남은 1개의 뭉치를 테스트로 사용하여 이를 5번 반복하여 평균을 구하는 5-fold 교차 검증을 수행하였다.

- **선형 회귀 결과**

  선형 회귀 모델을 사용하였을 때 성능은 아래 표 12와 같다. 테스트 데이터에 대한 결정 계수 값은 0.42로 총 분산 중 42%를 선형 회귀 모델을 사용하여 예측 가능하며, 스피어만 상관 계수 값은 0.654로 표 9, 10, 11에서 살펴본 선행 연구들의 해석 기준에 따르면 두 변수간의 관계가 중간 혹은 높은 상관 관계가 있다고 해석할 수 있다.

	선형 회귀
결정 계수(트레이닝)	0.449
결정 계수(테스트)	0.42
스피어만 상관계수	0.654
유의 확률(p-value)	< .0001

표 12. 선형 회귀 모델 성능.

- **신경망 결과**

신경망 모델 구조에 따른 예측 성능을 측정하기 위하여 실험을 진행하였다. Heaton, J.에[12] 따르면 은닉층의 뉴런 개수를 정하기 위한 경험적인 법칙(Rule-of-thumb methods)이 있다. 법칙은 1) 은닉층의 뉴런 개수는 입력층의 크기와 출력층의 크기 사이에 존재해야한다. 2) 은닉층의 뉴런 개수는 입력층의 크기의 ⅔ + 출력층의 크기여야 한다. 3) 은닉층의 뉴런 개수는 입력층의 크기의 두배보다 더 적어야한다 와 같다.

위의 법칙에 기반하여 은닉층의 뉴런 개수가 [10, 15, 20, 25, 30, 35, 40, 45, 50]에서의 예측 성능을 측정하였고 그 결과는 표 13과 같다. 뉴런 개수가 50개 이상인 경우에 과적합(Overfitting) 현상이 발생하였다. 그림 9, 10에서의 결과를 기반으로 최종적으로 선택된 모델의 성능은 테스트 데이터에 대한 결정 계수 값은 0.4559로 총 분산 중 45%를 예측 가능하며, 스피어만 상관 계수 값은 0.679로 선형 회귀 모델의 결과보다 근소하게 높은 것을 확인할 수 있고, 표 9, 10, 11에서 살펴본 선행 연구들의 해석 기준에 따르면 두 변수간의 관계가 중간 혹은 높은 상관 관계가 있다고 해석할 수 있다.

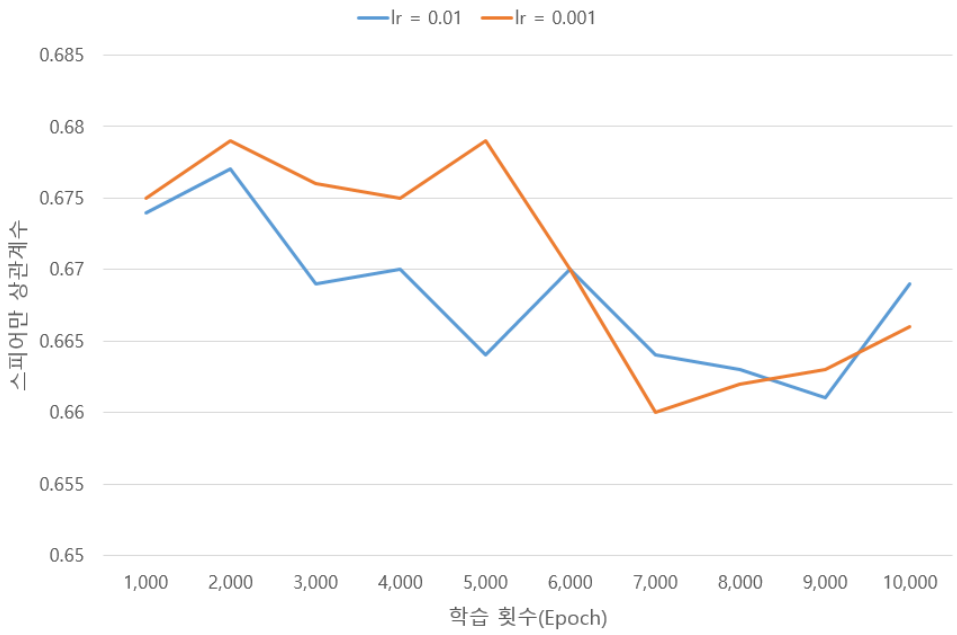

그림 9. 학습 횟수(1,000−10,000)와 학습 속도(0.01, 0.001)에 따른 스피어만 상관 계수 결과.

그림 10. 학습 횟수(1,000−10,000)와 학습 속도(0.01, 0.001)에 따른 결정 계수 결과.

뉴런 개수	결정계수 (트레이닝)	결정계수 (테스트)	스피어만 상관계수	유의확률 (p-value)
10	0.4759	0.4338	0.663	< .0001
15	0.4792	0.4416	0.665	< .0001
20	0.483	0.437	0.664	< .0001
25	0.5021	0.4517	0.675	< .0001
30	0.5134	0.4451	0.671	< .0001
35	0.5026	0.449	0.674	< .0001
40	0.5184	0.4538	0.679	< .0001
45	0.5201	0.4475	0.669	< .0001
50	0.5353	0.454	0.677	< .0001

표 13. 은닉층의 뉴런 개수에 따른 예측 성능 결과.

4.2 특성 중요도(Feature Importance)

본 연구에서는 흥미도 예측 점수에 각 특성들이 유의미하게 영향을 주는지를 알아보고자 선형 회귀 모델에서 이를 분석하였다. 결과는 표 14과 같고, 예측에 유의미한 영향을 주는 특성들로는 사진 존재 여부, 글 존재 여부, 사진 개수, 알림 보낸 사람과 함께 아는 친구 수, 알림에서의 직접적인 사용자 언급 여부, 알림 보낸 사람과의 친밀도가 해당된다.

	Estimate	Std. Error	T value	Pr(>|t|)
수신 시간	−0.062	0.045	−1.391	0.164
보낸 사람 : 시스템	−0.231	0.26	−0.887	0.374
보낸 사람 : 사용자	0.186	0.275	0.678	0.497
사진	−0.611	0.077	−7.881	< .0001
글	−0.316	0.059	−5.28	< .0001
사진 개수	0.042	0.015	2.701	< .001
가입한 그룹	0.28	0.271	1.033	0.301
함께 아는 친구 수	0.001	0.0004	3.875	< .0001
공개 그룹	0.179	0.124	1.442	0.149
직접적인 사용자 언급 여부	0.299	0.09	3.311	< .0001
친밀도	0.7497	0.029	25.531	< .0001

표 14. 선형 회귀 모델의 특성 중요도 분석 결과.

5. 사용자 실험

본 연구에서 설계한 흥미도 예측 모델을 사용하여 흥미도 점수가 높은 순서대로 정렬한 Facebook 알림 목록에 대한 사용성을 평가하기 위하여 본 사용자 실험을 진행하였다.

5.1. 실험 설계

5.1.1. 실험 개요

참여자의 알림 목록에서 가장 최근에 수신한 순서대로 아직 사용자가 읽지 않은 50개의 알림을 데이터로 사용한다. 50개의 알림으로 구성된 알림 목록에서 홀수 번호의 알림 25개와 짝수 번호의 알림 25개로 나누어 두 그룹을 생성하고, 각 그룹에 속하는 알림들로 두 종류의 알림 목록을 생성한다. 하나의 알림 목록은 Facebook에서 현재 사용 중인 수신 시간 정렬 방식을 그대로 사용하여 구성하고, 다른 하나의 알림 목록은 본 연구에서 설계한 흥미도 예측 모델을 사용하여 흥미도 점수가 높은 순서대로 정렬하였다. 참여자에게는 두 알림 목록 모두 흥미도 점수를 예측하는 임의의 알고리즘을 사용하여 흥미도 점수가 높은 순서대로 내림차순으로 정렬된 결과라고 안내하였다. 사용자가 알아보지 못하도록 두 알림 목록 모두 알림의 수신 시간을 삭제하였다. 참여자는 각 알림 목록에 대해서 다음의 두 가지의 태스크를 수행하였다.

첫 번째 태스크는 각 알림 목록의 25개의 알림 중에서 알림 목록에 나와있는 정보만으로 가장 흥미로워보이는 5개의 알림을 선택하는

것이다. 두 종류의 알림 목록에 대해서 첫 번째 태스크를 수행한 이후에 두 번째 태스크로, 참여자는 선택한 총 10개의 알림에 대해서 실제로 알림의 내용을 확인한 후에 흥미도 점수를 평가하였다.

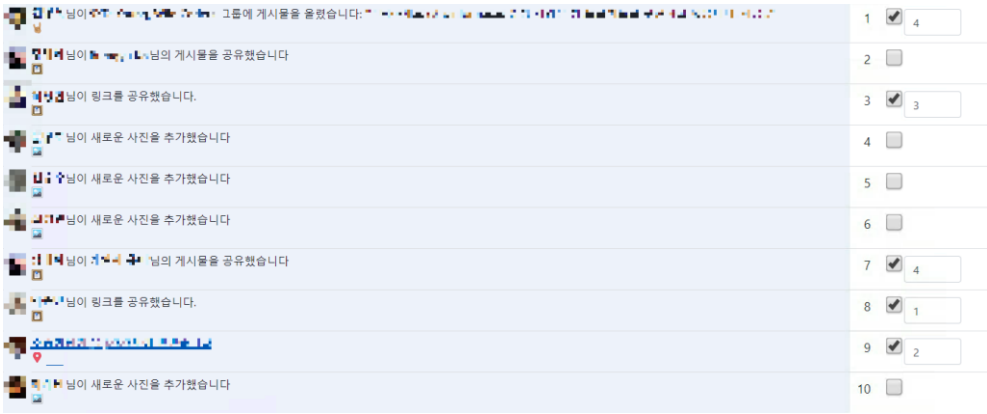

그림 11. 사용자 실험 환경. 흥미로운 알림을 선택할 때는 오른쪽의 체크 박스를 선택하고, 흥미도 점수는 체크 박스의 오른쪽 빈칸에 입력한다.

5.1.2. 독립 변수

- 알림 목록 정렬 기준

  Facebook상의 알림 목록을 정렬할 때 알림을 수신한 시간 순서대로 정렬하는 경우와 알림의 흥미도 점수를 예측한 결과를 기반으로 흥미도 점수 순서대로 정렬하는 경우 총 2가지로 구분하였다.

참여자들은 수신 시간 기준 정렬 방식과 흥미도 점수 기준 정렬 방식 총 2가지의 알림 목록에서 탐색하였으며, 알림 목록을 탐색하는 순서는 학습 효과(learning effect)를 방지하기 위해 라틴 스퀘어 설계(Latin square design, [15])를 통해 counter-balanced 하였다.

5.1.3. 종속 변수

- 알림 탐색 수행 시간

  첫번째 태스크에서 참여자는 알림 탐색을 수행한다. 이 때 수행 시간은 참여자가 흥미롭다고 생각하는 알림을 찾기 위해 알림 목록을 탐색하는 시간을 의미하는 것으로, 이는 알림 탐색의 효율성의 지표로 볼 수 있다. 수행 시간은 알림 목록을 처음 본 후부터 5가지의 흥미로운 알림을 모두 선택한 후에 제출하기 버튼을 누른 시간까지 측정하도록 하였다.

- mAP(Mean Average Precision)

  mAP는 쿼리 집합에서의 각 쿼리에 대한 평균 정확도(Average Precision) 점수를 더해 평균을 구한 값으로, 추천 시스템의 성능을 평가하는 지표 중 하나이다. mAP값이 더 클수록 추천 알고리즘의 성능이 더 좋다고 해석할 수 있으며, 본 실험에서는 두 종류의 알림 목록에서 사용자가 흥미롭다고 판단한 알림의 순위(Rank) 데이터를 통해 mAP값을 구할 수 있다.

- 흥미도 점수

  흥미도 점수는 참여자가 두 종류의 알림 목록에서 흥미로운 알림을 얼마나 잘 찾을 수 있었는지를 판단하기 위한 지표이다.

5.1.4. 실험 참여자

총 8명의 Facebook 사용자가 참여하였다. 흥미도 평가 실험에서 세웠던 참여자 조건을 그대로 사용하면서 현재 사용자가 읽지 않은 알림이 60개 이상이어야 한다는 조건을 추가하였다. 6번 참여자는 실험

도중에 실험자의 개인 사정으로 인하여 실험을 중단하였기 때문에 최종 실험 결과에서는 제외하였고, 결과적으로 총 7명의 참여자 결과만 분석하였다.

5.2 실험 결과

5.2.1. 수행 시간

대응 표본 t 검정(Paired Sample t-test)을 통해 25개의 알림 중 5개의 흥미로운 알림을 선택하는 태스크를 수행할 때 정렬 기준(시간 순서, 흥미도 순서)에 따른 수행 시간의 차이를 분석한 결과, 흥미도 정렬을 사용했을 때 수행 시간이 짧았으나 유의미한 차이는 나타나지 않았다($T(6) = 1.042$, $p = 0.337 > .05$)(그림 12).

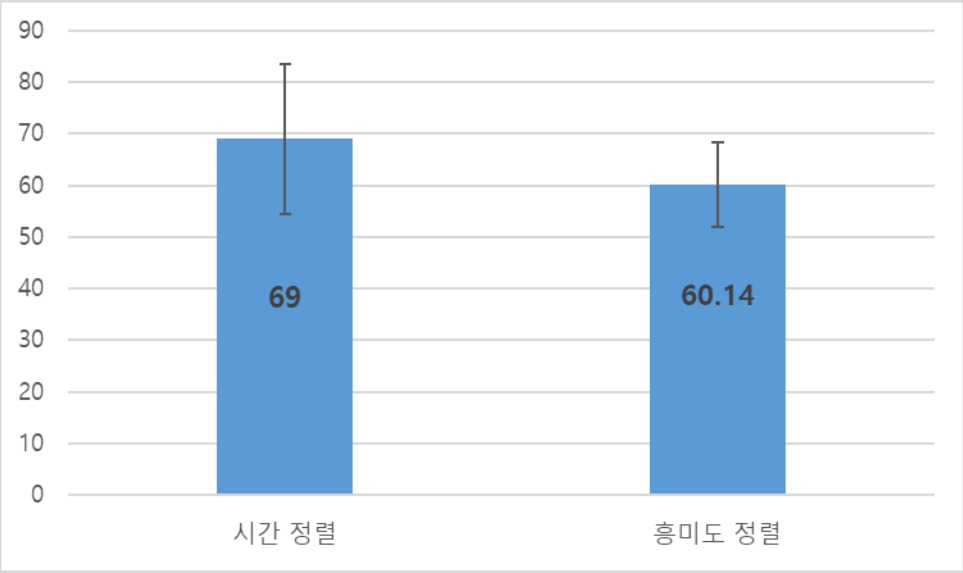

그림 12. 시간 정렬(SD=1.25)과 흥미도 정렬(SD=1.13)에 따른 평균 수행 시간(s). 오차 막대는 표준 오차를 나타낸다.

5.2.2. mAP

대응 표본 t 검정(Paired Sample t-test)을 통해 25개의 알림 중 5개의 흥미로운 알림을 선택하는 태스크를 수행할 때 정렬 기준(시간 순서, 흥미도 순서)에 따른 mAP 점수 차이를 분석한 결과, 흥미도 정렬일 때 mAP가 높았으나 유의미한 차이는 나타나지 않았다($T(6) = -2.38$, $p = 0.055 > .05$)(그림 13).

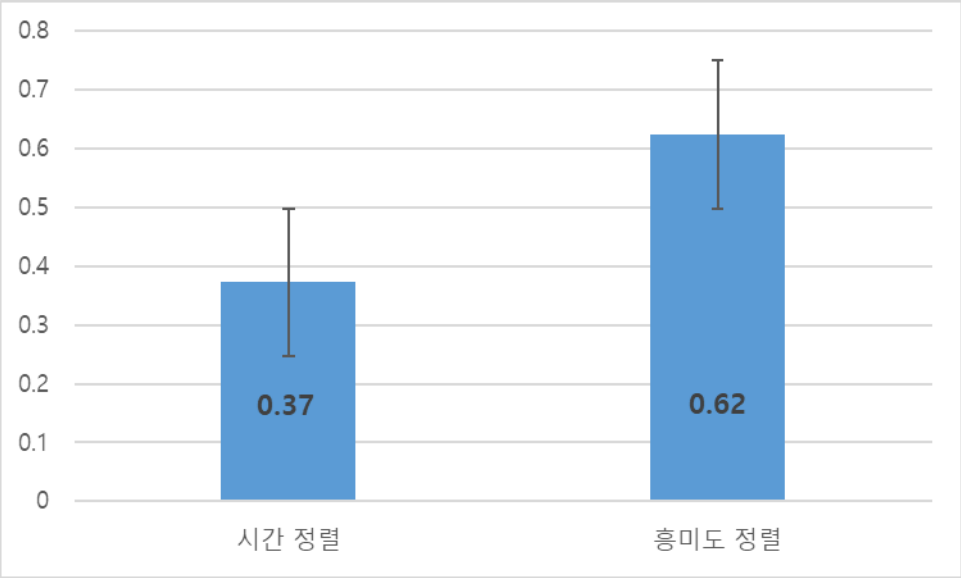

그림 13. 시간 정렬과 흥미도 정렬에 따른 평균 mAP. 오차 막대는 표준 오차를 나타낸다.

5.2.3. 흥미도 점수

대응 표본 t 검정을 통해 5개의 알림의 흥미도 점수를 평가하는 태스크를 수행할 때 정렬 기준(시간 순서, 흥미도 순서)에 따른 흥미도 점수의 차이를 분석한 결과, 정렬 기준에 따른 수행 시간에서 유의미한 차이를 발견할 수 있었다($T(6) = -2.644$, $p = 0.038 < .05$)(그림 14).

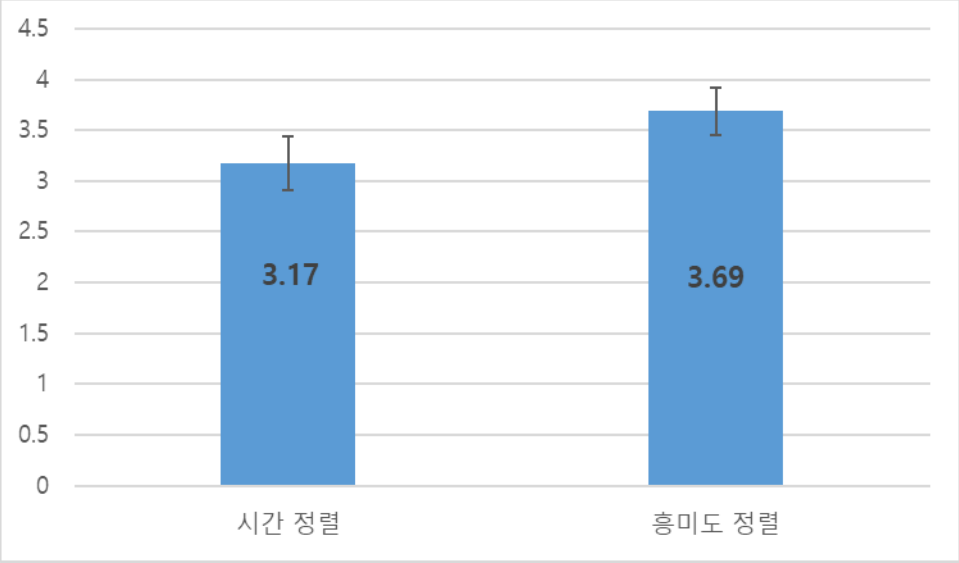

그림 14. 시간 정렬과 흥미도 정렬에 따른 평균 흥미도 점수. 오차 막대는 표준 오차를 나타낸다.

5.2.4. 주관 평가 점수

주관 평가는 총 3가지의 질문으로 구성했으며, 실험 참여자는 동일한 질문에 대해 정렬 방식에 따라 두 번 응답하였다. 각 질문의 점수에 대해 정렬 방식의 차이를 비교해보았다. 답변과 점수는 매우 아니다(1) – 조금 아니다(2) – 보통이다(3) – 조금 그렇다(4) – 매우 그렇다(5) 와 같다.

- “나는 ()로 정렬된 알림 목록을 다음에도 사용하고 싶다.”

  대응 표본 t 검정을 통해 정렬 기준(시간 순서, 흥미도 순서)에 따른 해당 질문의 점수 차이를 분석한 결과, 흥미도 순서일 때 더 긍정적이었으나 유의미한 차이는 나타나지 않았다($T(6) = -0.714$, $p = 0.356 > .05$)(그림 15).

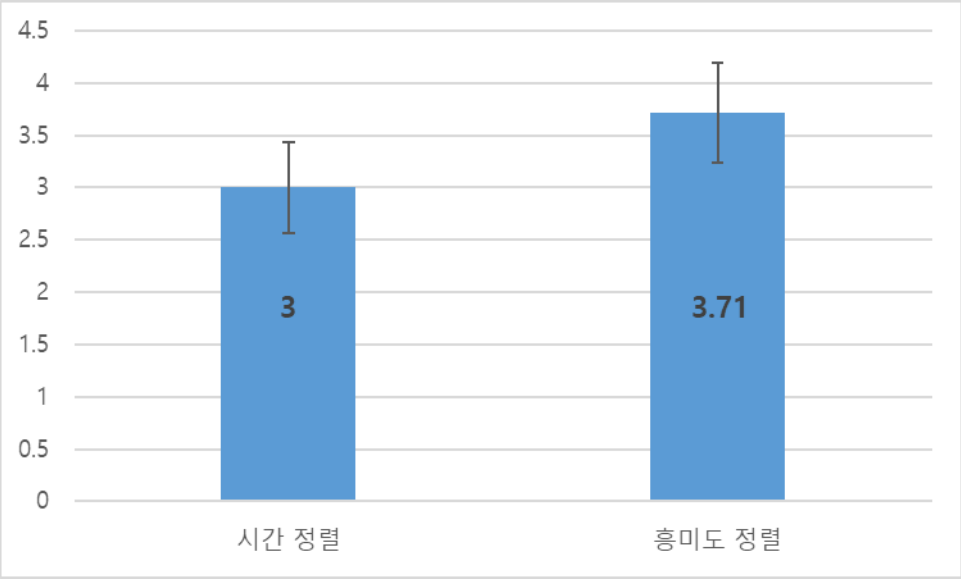

그림 15. 시간 정렬과 흥미도 정렬에 따른 질문 1의 답변 점수. 오차 막대는 표준 오차를 나타낸다.

- “나는 ()로 정렬된 알림 목록을 사용할 때 흥미로운 알림을 찾기가 더 쉬웠다.”

  대응 표본 t 검정을 통해 정렬 기준(시간 순서, 흥미도 순서)에 따른 해당 질문의 점수 차이를 분석한 결과, 흥미도 순서일 때 더 긍정적이었으나 유의미한 차이는 나타나지 않았다($T(6) = -1.143$, $p = 0.156 > .05$)(그림 16).

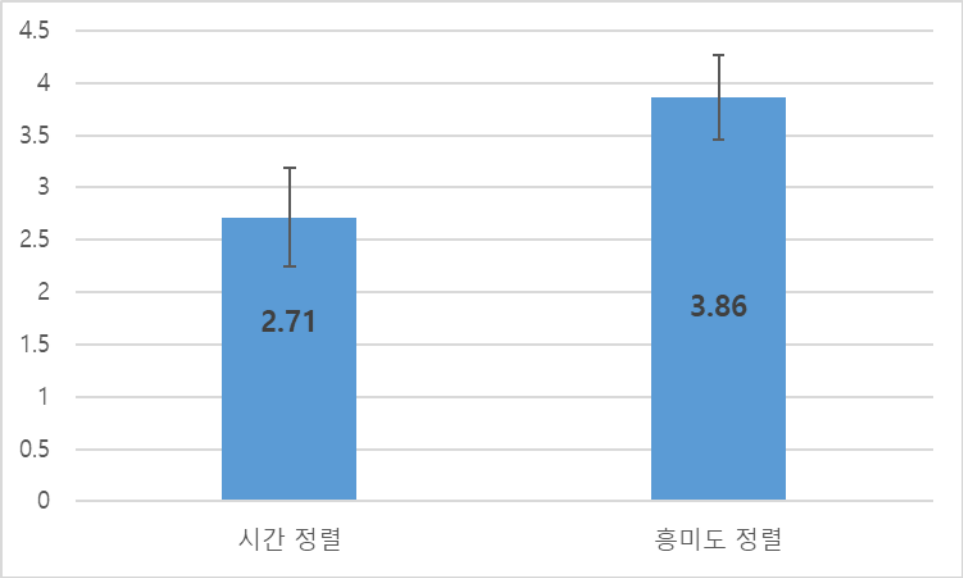

그림 16. 시간 정렬과 흥미도 정렬에 따른 질문 2의 답변 점수. 오차 막대는 표준 오차를 나타낸다.

- “나는 ()로 정렬된 알림 목록을 사용하면 알림을 탐색할 때 도움이 될 것이라고 생각한다.”

  대응 표본 t 검정을 통해 정렬 기준(시간 순서, 흥미도 순서)에 따른 해당 질문의 점수 차이를 분석한 결과, 흥미도 순서일 때 더 긍정적이었으나 유의미한 차이는 나타나지 않았다($T(6) = -0.857$, $p = 0.248 > .05$)(그림 17).

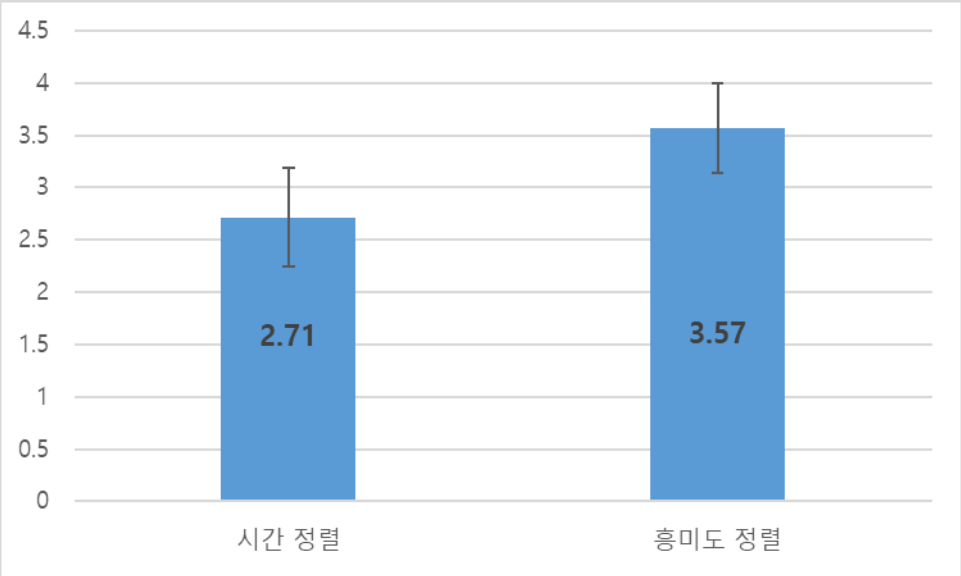

그림 17. 시간 정렬과 흥미도 정렬에 따른 질문 3의 답변 점수. 오차 막대는 표준 오차를 나타낸다.

6. 논의

본 절에서는 사용자 실험 결과와 설문 조사 및 인터뷰 결과로부터 흥미도 예측 점수 기반 정렬 방식의 장단점을 논의하고, 향후 추가적으로 개선 가능한 방향을 살펴본다. 흥미도 점수를 기준으로 정렬한 알림 목록에서의 수행 시간, 흥미도 점수, 주관 평가 점수에 대해 분석하였다.

- **수행 시간**

  수신 시간을 기준으로 정렬한 알림 목록과의 평균값의 차이와 유의수준 값(=.337)을 고려한 결과, 흥미도 기준 정렬 방식을 사용한 경우가 근소하게 수행 시간이 감소하였으나 그 차이가 유의미하지는 않았다. 이는 대부분의 참여자들이 알림 목록의 상위권에서 흥미로운 알림들을 발견하였으나, 알림 목록에 존재하는 총 25개의 알림을 모두 확인한 후에 최종적으로 결정하는 경향을 보였는데, 이로 인해 두 방식의 수행 시간이 유의미하게 차이 나지 않은 것으로 보인다.

- **흥미도 점수**

  수신 시간을 기준으로 정렬한 알림 목록과의 평균값의 차이와 유의수준 값(=.038)을 고려한 결과, 흥미도 기준 정렬 방식을 사용한 경우가 유의미한 차이로 알림의 흥미도 점수가 더 높다는 것을 확인하였다. 이는 참여자들이 흥미도 점수 순서로 정렬된 알림 목록에서 실제로 흥미로운 알림을 더 잘 찾을 수

있다는 것을 정량적으로 확인한 것으로 볼 수 있다. 인터뷰 결과에서도 7명 중 6명의 사용자가 흥미도 순서로 정렬된 알림 목록에서 흥미로운 알림을 더 찾기 쉬웠다고 응답하였다.

- **주관 평가 점수**

총 3가지의 주관 평가 질문에 대하여 수신 시간을 기준으로 정렬한 알림 목록과의 평균값의 차이와 유의수준 값(질문 1의 p=.356, 질문 2의 p=.156, 질문 3의 p=.248)을 고려한 결과, 세 질문 모두 흥미도 기준 정렬 방식을 사용한 경우가 근소하게 점수가 높았으나 그 차이가 유의미하지는 않다. 1명의 참가자만 제외하고는 모두 흥미도 순서를 더 선호한다고 응답하였다. 1번 참가자만 시간 순서로 정렬된 알림 목록을 더 선호한다고 응답하였는데, 그 이유로는 "대부분의 알림이 (정렬 알고리즘과 무관하게) 관심이 없는 알림이기 때문"이라 답하였다. 그럼에도 불구하고 시간 순서 정렬을 선호한 이유에 대해 인터뷰를 진행한 결과, 알림 목록 중 하나의 흥미로운 알림이 해당 목록에 존재했기 때문이라 응답하였다.

그 외에도 2번 참가자는 흥미도 점수 기준 정렬 알림 목록이 흥미로운 알림을 찾는 태스크에는 유용하였지만, 알림 탐색에는 크게 도움이 되지 않을 것 같다고 응답하였다. 그 이유로는 2번 참가자의 알림 탐색 목적은 알림을 통하여 다양한 소식을 접하기 위한 것인데, 흥미도 기반 정렬은 친밀도가 높은 사용자들에 대해서만 편중된 것 같다고 응답하였다. 이는 4.2.절에서 확인한 바와 같이 흥미도 점수에 유의미하게 가장 큰 영향을 미치는 특성이 보낸 사람과의 친밀도이기 때문에 해당

응답이 나온 것으로 보인다. 위 응답으로 미루어 봤을 때, 알림 목록을 다양한 소식을 접하기 위한 목적으로 탐색하는 사용자도 고려한다면, 시간과 흥미도 기준을 적절히 혼합하여 사용하는 알림 목록 또한 유용할 가능성이 높아 보인다.

7. 한계 및 향후 연구

본 연구에서는 진행 과정 중에 고려하지 못했거나 현실적인 한계로 인하여 발생한 한계점들이 있다. 첫 번째로, 본 연구에서는 가장 일반적인 SNS의 특징을 담고 많은 사용자를 보유한 Facebook을 대상으로 한 연구로, 사진 컨텐츠를 다루는 Instagram 등 다른 종류의 SNS 특징은 모두 반영하지 못하였다.

두 번째로, 본 연구는 Facebook에서 공식적으로 제공하는 정보에 대해서만 접근이 가능하므로 흥미도 점수를 예측할 때 사용하는 특성을 탐색하는 과정이 제한되어 있다는 한계점이 있다. 예를 들어, 사용자와 관계를 맺은 다른 사용자들과의 주고받은 인터랙션 정보(메시지, 현재까지 특정 사용자로부터 받은 알림의 개수 등)나 Facebook 상에서 알고 지낸 기간 등의 정보를 알 수 없었기 때문에 본 연구에서는 데이터 수집 과정에서 추가적으로 사용자들과의 친밀도 점수를 입력 받았다. 또한, 사용자의 사생활 보호 문제로 인해 사용자의 알림 내용 데이터는 접근이 어려웠다는 한계점도 있다.

이외에도, Facebook 알림의 흥미도 평가 실험에서 수집된 데이터 수가 부족하다는 한계점이 있다. 대부분의 관련 연구에서는 앱의 배포를 통해 많은 수의 데이터를 수집하였지만, 본 연구의 Facebook 환경에서는 해당 방법을 사용하는 것이 불가능하였다. 그러므로 정해진 실험 장소에서 참여자로부터 데이터를 직접 수집해야 했으므로, 수집된 데이터의 수가 부족하다는 한계점이 있다. 향후에 추가적으로 데이터를

수집하여 흥미도 예측 모델을 재설계하고, 예측 성능을 향상시킬 수 있다.

마지막으로, 흥미도 점수를 기준으로 정렬한 알림 목록의 사용성을 검증하기 위해 본 연구에서는 실험을 총 25개의 알림 중 가장 흥미로운 알림 5개를 선택하도록 설계하였다. 이 과정에서 참여자 모집 조건 중 하나인 읽지 않은 Facebook 알림이 최소 60개 이상이어야 한다는 조건으로 인해 실험 참여자가 부족하다는 한계점이 있다. 또한 실제로 알림을 탐색하는 환경에서 사용자는 제한된 개수의 흥미로운 알림만 선택하는 것이 아니라 다양한 목적으로 사용할 수 있다. 그러므로 본 연구에서 제안한 알림 목록의 사용성을 검증하기 위해서는 실제 환경에서의 실험 또한 추가적으로 진행할 필요가 있다.

8. 결론

본 논문에서는 SNS 사용자들이 알림 목록 상에서 알림을 탐색할 때 흥미로운 알림을 효율적으로 찾을 수 있도록 도움을 주기 위하여, 알림을 흥미도 순서로 정렬한 알림 목록을 제안한다. Facebook 알림 탐색 과정에서 발생하는 문제점을 정의하고, 해당 문제점을 해결하기 위해 흥미도 점수를 기반으로 알림을 정렬한 알림 목록이 사용될 수 있는 가능성을 살펴보았다. 알림의 흥미도 평가 실험을 통하여 모델을 설계하기 위한 학습 데이터를 수집하였고, 스피어만 상관 계수 값이 0.679, 결정 계수 값은 0.453 의 예측 성능을 보였다. 또한 사용자 실험 진행한 결과, 흥미도 점수를 기준으로 정렬된 알림 목록에서 사용자가 흥미로운 알림을 더 많이 찾을 수 있다는 것을 확인하였다. 향후 연구를 통하여 더 많은 데이터를 수집함으로써 흥미도 예측 모델을 개선하고, 알림 목록을 탐색할 때 다양한 목적을 가진 사용자들의 알림 목록에도 적용 가능하도록 확장할 계획이다.

참고문헌

[1] Anderson, Christoph, et al. "A Survey of Attention Management Systems in Ubiquitous Computing Environments." arXiv preprint arXiv:1806.06771 (2018).

[2] Bouraga, Sarah, Ivan Jureta, and Stéphane Faulkner. "An empirical study of notifications' importance for online social network users." Social Network Analysis and Mining 5.1 (2015): 51.

[3] Boyd, Danah M., and Nicole B. Ellison. "Social network sites: Definition, history, and scholarship." Journal of computer-mediated Communication 13.1 (2007): 210-230.

[4] Mehrotra, Abhinav, et al. "Designing content-driven intelligent notification mechanisms for mobile applications." Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing. ACM, 2015.

[5] Mehrotra, Abhinav, Robert Hendley, and Mirco Musolesi. "PrefMiner: mining user's preferences for intelligent mobile notification management." Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing. ACM, 2016.

[6] Mehrotra, Abhinav, et al. "My phone and me: understanding people's receptivity to mobile notifications." Proceedings of the 2016 CHI conference on human factors in computing systems. ACM, 2016.

[7] Pielot, Martin, et al. "Didn't you see my message?: predicting attentiveness to mobile instant messages." Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. ACM, 2014.

[8] Pielot, Martin, Karen Church, and Rodrigo De Oliveira. "An in-situ study of mobile phone notifications." Proceedings of the 16th international conference on Human-computer interaction with mobile devices & services. ACM, 2014.

[9] Sahami Shirazi, Alireza, et al. "Large-scale assessment of mobile notifications." Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. ACM, 2014.

[10] Yuan, Fengpeng, Xianyi Gao, and Janne Lindqvist. "How busy are you?: Predicting the interruptibility intensity of mobile users." Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems. ACM, 2017.

[11] Davis, James A. Elementary survey analysis. No. 519.5. 1971.

[12] Heaton, Jeff. Programming neural networks with Encog 2 in Java. Heaton Research, Inc., 2010.

[13] Hinkle, Dennis E., William Wiersma, and Stephen G. Jurs. "Applied statistics for the behavioral sciences." (1988).

[14] Hopkins, Will G. "A new view of statistics." (1997).

[15] Winer, Benjamin J, “Latin squares and related designs.” (1962).

[16] Gmail, Retrieved November 19, 2018 from https://support.google.com/mail/answer/186543?hl=ko&p=inbox styles&visit_id=636778101271481269-751860389&rd=1

[17] Facebook, Retrieved November 19, 2018 from https://www.facebook.com

Abstract

A notification list is a common component in many Social Network Services (SNS) such as Facebook. Notifications are usually sorted by their arrival time, so that users can navigate the most recent notification first. However, this can limit the navigation process with a possibility of missing interesting notifications. Indeed, our survey revealed that users have various criteria in judging the interestingness of a notification in addition to its arrival time, such as its event type, sender, and content. We propose a new notification list for Facebook that predicts the interestingness of notifications and shows them in an *interestingness* order. For prediction, we collected 1,988 notification and interestingness pairs from 23 users and built a two-layer neural network. Our prediction network showed a Spearman's rank correlation coefficient of 0.679 and the coefficient of determination value of 0.453 that suggests moderate to high correlation. Finally, we compared our list with a conventional chronologically sorted list. Our user study revealed that users could find significantly more interesting notifications with our list than with a previous one as well as preferring ours.

Keywords : Social Network Services, notification, predictive model, linear regression, neural network

Student Number : 2017-24950