

사물인터넷(IoT)과 추천시스템

IoT(Internet of Things) and Recommendation System

김 태 석(배재대학교)

차 례

1. 서론
2. 추천시스템
3. IoT 환경에서의 추천 시스템 연구 동향
4. 맺음말

■ keyword : | 추천 시스템 | IoT | 기계학습 | 딥러닝

1. 서론

정보의 양이 폭발적으로 증가함에 따라 사용자들이 인터넷에서 필요한 정보를 찾는데 많은 어려움을 겪고 있다. 오프라인 상점이 오직 인기 있는 상품만을 제공하는 반면, 온라인 상점은 모든 상품을 진열할 수 있는 롱테일(Long tail) 현상도 정보의 과부하에 따른 결과라 할 수 있겠다. 이러한 정보 과부하로 인해 발생하는 문제들을 해결하기 위해 사용자의 취향과 선호도를 고려하여 사용자에게 맞는 정보를 제공해주는 추천시스템이 그 어느 때보다도 중요해졌다. 추천 시스템은 사용자의 기호, 관심 또는 항목에 대한 관찰된 행동에 따라 동적으로 생성된 많은 양의 정보 중 중요한 정보를 필터링하여 정보 과부하 문제를 처리하는 일종의 정보 필터링 시스템이다. 실제로 추천 시스템은 많은 온라인 웹 사이트 및 모바일 응용 프로그램의 판매 및 서비스를 위한 중요한 도구로 활용되고 있는데 Netflix에서 시청한 영화의 80%, YouTube의 홈페이지 동영상 클릭의 60%는 추천 시스템의 결과이다[1].

최근 IoT(Internet of Things) 기술이 크게 발전하며 TV나 냉장고와 같은 가전제품뿐만 아니라 손목시계, 자동차 등에 센싱 및 통신 모듈이 탑재되는 등 다양한 종류의 IoT 기기가 출시되고 있다[2]. IoT 기기에서 생성되는 데이터에는 부착되어있는 센서로부터 얻을 수 있는 상황정보나 사용자 정보 등이 포함된다. 이러한 데이터는 사용자 상황에 대한 인지를 가능하게 하며 추천 서비스 측면에서 사용자가 원하는 서비스를 더욱 정확히 예측하여 제공할 수 있게 해준다.

기존 온-오프라인 추천시스템 환경과는 달리 IoT 환경에서는 단말기로부터 나오는 많은 데이터를 실시간으로 분석해야하기 때문에 데이터를 쉽고 빠르게 처리할 수 있는 IoT 환경을 위한 추천시스템에 대한 연구의 필요성이 증대되고 있다.

본고에서는 IoT 환경을 위한 추천 시스템 연구 동향과 발전 방향에 대해 살펴보고자 한다. 먼저, 추천시스템에 대한 개요와 대표적인 접근 방식을 살펴본다. 그리고 IoT 환경을 위한 최근의 추천 시스템 연구 동향을 소개한다. 마지막으로 향후 IoT 환경에서의 추천 시스템의 발전 방향을 제시하고자 한다.

2. 추천시스템

2.1 개요

추천 시스템은 사용자가 흥미를 갖거나 구매하기 원하는 상품을 쉽게 찾도록 도와주는 데이터 분석 기술 기반의 정보 필터링 (information filtering) 시스템을 일컫는다[3]. 추천 시스템은 개인화된 콘텐츠 및 서비스를 제공함으로써 사용자가 일반적으로 겪게 되는 정보 과부하 문제를 처리한다. 추천 시스템에 부여된 정의와 의미는 다양하다. 추천시스템은 복잡한 정보 환경에서 사용자를 위한 의사 결정 전략으로 정의된다[4]. 또한 추천 시스템은 전자 상거래의 관점에서 사용자의 관심과 선호도와 관련된 지식 기록을 검색하는 데 도움이 되는 도구로 정의된다[5]. 추천 시스템은 대안에 대한 충분한 지식이나 경험이 없을 때 다른 사람들의 추천을 사용하여 사회적

프로세스를 지원하고 보강하는 수단의 의미가 있다[6]. 또한, 추천 시스템은 고객들의 구매 편의를 도모하고 교차판매 및 매출 증대에 초점을 맞춘 시스템이다[7].

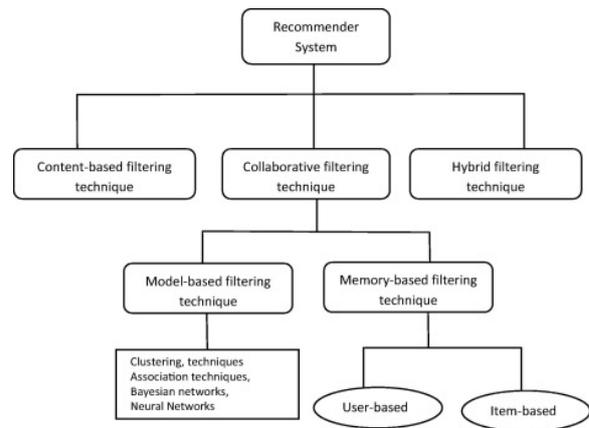
추천에서 사용할 수 있는 정보는 크게 (1) 판매하는 아이템(항목)에 대한 주로 텍스트로 표현되는 메타 정보와 (2) 사용자의 구매 항목에 대한 평가 정보인데 이 중 어떠한 정보를 기반으로 하는지에 따라 콘텐츠기반 필터링(content-based filtering)과 협업 필터링(collaborative Filtering)으로 나뉜다(그림 1). 콘텐츠기반 필터링은 상품 간의 유사성(item-to-item similarity)을 기반으로 하여 추천 결과를 생성하지만, 협업 필터링은 사용자 간 유사성(user-to-user similarity)에 따라 추천결과를 생성한다. 협업 필터링이 콘텐츠기반 필터링 보다 상대적으로 우수한 추천 정확도를 보이기 때문에 가장 대표적인 추천 기법으로 알려져 있다[8]. 이 외에도 두 방식의 단점을 보완하여 추천 시스템의 성능을 극대화하려는 하이브리드 필터링(hybrid filtering)도 최근 많은 연구가 되고 있다. 본고에서는 대표적인 추천 기법인 콘텐츠기반 필터링과 협업 필터링에 대해 자세히 살펴본다.

2.2 콘텐츠 기반 필터링

2.2.1 개요

콘텐츠 기반 필터링 기법에서는 과거에 사용자가 평가한 항목에서 추출한 특징을 이용하거나 사용자가 직접 작성한 아이템 선호도 프로파일을 기반으로 아이템과 아이템 혹은 아이템과 사용자 선호도간 유사성을 분석하여 이를 토대로 고객에게 아이템을 추천해주는 방식이다[9].

콘텐츠 기반 필터링이 활용하는 아이템의 메타 정보는 보통 텍스트 데이터인 경우가 대부분이기 때문에, 텍스트 정보를 기반으로 각 아이템에 대한 정보를 가공한다. 이를 위해, 아이템을 기술하기 위해 사용된 단어들의 출현 빈도수를 이용하여, 특정 아이템을 벡터로 표현한다. 이렇게 구성된 벡터를 기반으로 사용자의 선호도 프로파일을 유추하거나, TF-IDF(Term Frequency times Inverse Document Frequency: 단어 빈도 역문서 빈도)와 같은 벡터 공간 모델이나 Naive Bayes Classifier, Decision Trees 또는 Neural Networks와 같은 Probabilistic 모델을 사용하여 아이템-아이템간의 유사도를 계산한다.



▶▶ 그림 1. 추천 시스템 분류 [10]

2.2.2 장단점

협업필터링에서는 추천 대상 고객과 취향이 비슷한 이웃 사용자를 찾기 위해 여러 사람의 평가점수 데이터가 필요한 반면, 콘텐츠기반 접근방식에서는 추천 대상 고객의 선호도를 파악하기 위해 자신만의 과거 구매이력이나 프로파일 정보가 이용된다[11]. 이는 추천하고자 하는 고객의 독립적인 정보만을 필요로 하므로, 다른 사용자의 정보가 부족할 경우에도 유용하게 쓰일 수 있는 동시에 사용자 간 프로파일을 공유하지 않고도 추천 아이템을 얻을 수 있으므로 개인 정보 보호가 보장된다. 아울러, 사용자 선호도 설정이 변경되면 짧은 시간 내에 추천 아이템을 조정할 수 있는 장점도 있다.

하지만, 콘텐츠 기반 필터링은 여러 가지 문제점을 안고 있다. 콘텐츠 기반 필터링의 성능은 아이템의 메타 데이터에 의존하기 때문에 아이템에 대한 풍부한 정보제공이 전제되어야 한다. 또한 사용자의 과거 구매이력을 통한 선호도 파악을 위해 충분한 사용자의 아이템 평가 점수가 없는 경우 성능이 저하된다. 평가 점수가 존재하지 않는 새로운 아이템에 관해서는 점수를 주기 전까지는 추천될 수 없는 First rater 문제도 존재한다[9]. 아울러, 자신만의 구매 이력과 프로필에 근거하여 추천하기 때문에 유사한 상품들만 추천되어 추천 상품의 다양성이 저해되는 과도한 특수화 역시 단점이다[9].

2.2.3 적용 사례

콘텐츠 기반 필터링은 분석의 용이함과 메타데이터의 가용성으로 인해 영화, 음악, 도서뿐만 아니라 텍스트 기반의 뉴스나 인터넷 기사 등을 추천하는데 널리 쓰이고 있다[11].

News Dude [12]는 합성 음성을 사용하여 사용자에게 뉴스 기사를 읽어 주는 개인 뉴스 시스템이다. 이 시스템은 TF-IDF 모델과 코사인 유사성 측정을 사용하여 단기 추천 뉴스를 결정한다. CiteSeer는 웹상에서 가장 광범위하게 사용되고 있는 연구 논문 저장소 중 하나로 콘텐츠 기반 필터링을 사용한 자동 인용 색인 서비스를 제공한다. LIBRA[13]는 웹에서 수집한 책에 대한 정보를 사용하는 콘텐츠 기반 도서 추천 시스템으로 웹에서 추출한 정보에 Naive Bayes 분류기를 구현하여 개별 사용자가 제공한 훈련 사례를 기반으로 순위가 매겨진 추천 목록을 생성한다.

2.3 협업 필터링

2.3.1 개요

협업 필터링 알고리즘은 사용자의 선호도와 유사한 선호도를 가진 다른 사용자들의 구매 정보를 사용하여 사용자에게 아이템이나 서비스를 추천하는 기법으로 가장 널리 사용되고 있다. 이 방식은 특정 아이템에 대해 선호도가 유사한 고객들은 다른 아이템에 대해서도 비슷한 선호도를 보일 것이라는 기본 가정을 바탕으로 한다. 협업 필터링과 콘텐츠 기반 필터링의 가장 큰 차이점은 사용자 이용 기록만으로 사용자-사용자, 사용자-아이템, 아이템-아이템간의 유사도를 측정하고, 측정된 유사도 정보만으로 추천 알고리즘을 구동하기 때문에, 추가적인 메타 정보를 요구하지 않는다는 점이다.

협업 필터링 기법의 추천은 4단계로 구성된다. 첫 단계에서는 사용자들이 아이템을 평가한 데이터를 기반으로 사용자-아이템 행렬을 생성하고 이를 기반으로 두 번째 단계에서 사용자 간에 유사도를 계산한다. 계산된 유사도를 기반으로 세 번째 단계에서 최근접 이웃을 선정하고 마지막 단계에서 최근접 이웃의 평가값을 기반으로 예측값을 생성하고 상위 N개의 아이템을 목표 사용자에게 추천한다. 협업필터링이 어떻게 동작되는지를 예제를 통해 살펴본다. 표 1은 5개의 아이템(I1~I5)에 대한 5명의 사용자(U1~U5)의 평가를 나타내는 사용자-아이템 행렬이다. 각 사용자는 아이템을 사용 후에 아이템에 대한 만족도를 점수(5점 만점)로 평가한다. 행렬에는 사용자간 유사도에 대한 정보(correlation 값)도 포함하고 있다. 만일 U1에게 협업필터링 기법으로 아이템을 추천한다면 아래와 같은 과정을 거친다.

1) 우선 U1과 취향이 비슷한 사용자를 찾는다. 취향은

아이템에 대한 평가로 나타날 것이므로 각 사용자들에 대한 평가의 유사성(similarity)을 계산한다. 맨 오른쪽 열에 U1과 다른 사용자의 상관계수가 표시되어 있다. 상관계수 값에 따르면 U3과 U4가 U1과 가장 높은 상관관계를 보이므로 이 둘을 취향이 비슷한 사용자 그룹인 Neighbor로 분류한다.

2) U3과 U4가 가장 좋게 평가한 아이템을 찾는다. U1이 아직 사용하지 못한 아이템인 I4와 I5에 대해서 U3과 U4의 평가의 평균은 각각 2와 5이다(맨 아래 행). 따라서 I5를 U1도 좋아할 것으로 예상할 수 있다.

3) I5를 U1에게 추천한다.

표 1. 협업필터링 동작 예 [14]

	I1	I2	I3	I4	I5	U1과의 상관계수
U1	2	5	3	-	-	-
U2	4	4	3	5	1	0.19
U3	1	5	4	-	5	0.89
U4	3	5	3	2	5	0.94
U5	4	5	3	4	-	0.65
U3과 U4의 평균	2	5	3.5	2	5	

협업 필터링은 크게 기억기반 협업 필터링과 모델기반 협업 필터링 두 가지 방식으로 나뉜다. 기억 기반 협업 필터링은 사용자 간 유사도를 계산한 뒤 유사도가 높은 사용자가 선택한 아이템을 추천하는 방식이다. 이 방식은 모델을 구축하지 않고 추천이 요구될 때마다 휴리스틱 기법을 통해 결과를 도출하는 'lazy learning'이다[9]. 모델 기반 협업 필터링은 기억 기반 협업 필터링 방식의 과정을 기본으로 하되 기억 기반 협업 필터링 적용 시 발생하는 유사도 측정 및 선호도 예측 등의 과정에서 발생하는 다양한 문제점을 보완하기 위해 베이지안, 선형 회귀분석, 마코프 결정 프로세스 등 이용 군집화, 분류, 예측의 단계에서 기계학습 또는 데이터마이닝 기법을 활용한다.

2.3.2 장단점

협업 필터링은 콘텐츠 기반 필터링에 비해 몇 가지 중요한 이점을 가지고 있다. 협업 필터링은 아이템과 관련된 콘텐츠가 많지 않고 컴퓨터 시스템에서 분석하기 어려운 콘텐츠(예: 의견 및 견해)가 있는 도메인에서 수행할 수 있다. 또한, 협업 필터링 기법은 사용자의 프로파

일 없이도 사용자와 관련된 뜻밖의 추천(serendipity)을 제공할 수 있는 능력을 가지고 있다[15]. 콘텐츠기반 필터링은 외부 정보를 필요로 한다는 한계점으로 인해, 다양한 도메인에 적용이 불가능하다. 따라서 비교적 도메인의 제약이 적은 협업 필터링이 널리 사용되고 있으며 Amazon.com, Netflix.com, CDNow.com 등 수많은 기업들이 협업필터링을 통해 고객에게 추천서비스를 제공하고 있다[16].

하지만, 협업 필터링이 널리 사용되면서 다음과 같은 몇 가지 잠재적인 문제가 밝혀졌다.

- 1) Cold start 문제: 새 사용자 또는 새 아이템의 프로파일은 항목을 평가하지 않았으므로 존재하지 않는다. 이것은 추천자가 선호도를 예측하는 것을 불가능하게 만드는데 이를 콜드 스타트라고 한다. 이는 추천 시스템의 성능을 저하시키는 주요 문제점 중 하나이다.
- 2) 데이터 희소성 문제: 이것은 정보가 부족하여 발생하는 문제이다. 일반적으로, 사용자와 아이템의 수가 굉장히 많아 데이터베이스에서 사용 가능한 총 아이템 중 소수만이 사용자에게 의해 평가될 때 발생한다. 이것은 항상 사용자-아이템 행렬을 희박(sparse)하게 만들어 추천 대상자에 대한 이웃들을 찾을 수 없게 만들어 추천 성능의 저하를 초래한다. 또한 데이터 희소성은 시스템 아이템 전체에 대비 추천되어 질 수 있는 비율인 적용 범위(coverage) 문제를 항상 발생시킨다[17].
- 3) 확장성: 최근 상품의 종류가 다양해지고 사용자가 늘어남에 따라 사용자-아이템 데이터 집합의 크기가 커지고 있으며, 이에 따라 추천 알고리즘 구현 시 컴퓨터 계산량이 급증하게 되어 많은 시간과 비용이 소모되는 문제점이 발생하고 있다[9]. 따라서 데이터 집합 수가 증가함에 따라 성공적으로 확장할 수 있는 추천 기법을 적용하는 것이 중요하다. 확장성 문제를 해결하고 추천 생성 속도를 높이기 위해서 SVD (Singular Value Decomposition) 방법과 같은 차원 축소 기술을 활용하는 것도 하나의 방법이다.
- 4) Gray sheep: 협업필터링은 사용자들의 취향에 있어 일정한 경향과 패턴이 존재한다는 가정을 하고 있으나 실제로는 일관성 없는 의견을 가진 사용자들의 데이터가 경향과 패턴을 파악함에 있어 방해

가 되어 예측 정확도를 떨어뜨릴 수 있는데 이 문제를 gray sheep이라고 한다.

2.3.3 적용 사례

GroupLens[18]는 대규모 뉴스 데이터베이스에서 기사를 찾는 데 도움이 되는 협업 필터링을 사용하는 뉴스 추천 시스템이다. GroupLens는 인터넷 토론 그룹 서비스인 Usenet 뉴스를 추천하는데 사용자와 뉴스는 시스템의 기존 뉴스 그룹을 기반으로 클러스터링되며 사용자가 뉴스를 읽는 데 걸리는 시간을 측정하여 뉴스 등급을 계산한다. 인터넷상의 뉴스의 수명이 짧다는 것과 사용자-뉴스 등급 행렬의 희소성은 이 시스템이 해결해야 할 두 가지 주요 문제이다.

Ringo [19]는 음악 앨범과 아티스트에 대한 추천을 하는 사용자 기반 협업 필터링 시스템이다. 사용자가 처음 시스템에 등록하면 125 명의 아티스트 목록이 사용자에게 제공된다. 목록은 두 개의 섹션으로 구성된다. 첫 번째 섹션은 가장 자주 평가받는 아티스트로 구성되는데 이를 통해 다른 사용자들도 평가했던 아티스트들에 대해 평가할 기회를 얻게 되고 결과적으로 다른 사용자와의 프로필 사이에 어느 정도의 유사성 수준이 형성된다. 두 번째 섹션은 전체 사용자-아이템 행렬에서 무작위로 항목을 선택하여 평가된다.

Amazon.com은 아이템 간 협업 필터링 기술을 사용하여 여러 사용자에게 온라인 제품을 추천한다. 사용되는 계산 알고리즘은 데이터베이스 내의 사용자와 아이템 수에 독립적으로 확장된다[20]. Amazon.com은 명시적인 정보 수집 기술을 사용하여 사용자로부터 정보를 얻는데 정보 획득을 위한 인터페이스는 다음 섹션, 인터넷 사용 기록, 아이템 평가, 추천 및 프로필 개선으로 구성된다. 시스템은 사용자가 평가한 아이템을 기반으로 사용자의 관심을 예측하고 시스템상의 사용자 브라우징 패턴을 비교하여 관심 있는 아이템을 결정한 후 사용자에게 추천한다. Amazon.com은 "이 아이템을 구입 한 사람들은 다음 아이템을 구입했습니다"라는 기능을 제공하였다. 그림 2는 Amazon.com의 아이템 간 추천 인터페이스의 예이다.



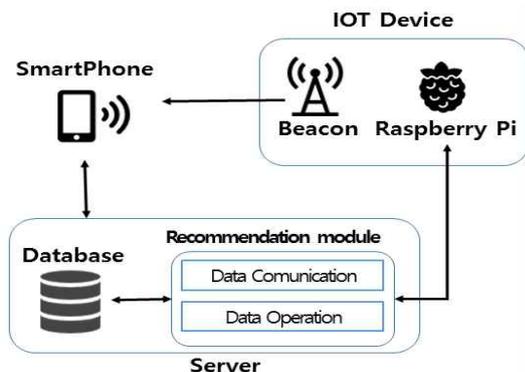
▶▶ 그림 2. 아마존 책 추천 인터페이스.

3. IoT 환경에서의 추천 시스템 연구 동향

IoT와 관련된 추천 시스템의 최근 연구 동향은 크게 두 갈래로 나뉠 수 있다. 1) IoT 기기로부터의 contexture 정보를 추천에 활용하여 추천 결과의 고도화를 달성하려는 연구, 2) 센서, 단말기로부터 나오는 많은 데이터를 실시간 처리 및 분석해야 하는 어려움을 극복하려는 연구들이다.

3.1 IoT 환경에서의 contextual data를 활용한 추천시스템

IoT 환경에서는 기존 가전제품뿐만 손목시계, 자동차 등과 같은 IoT 기기로부터 발생하는 대량의 데이터가 상황정보나 과거기록 등을 제공해 줄 수 있는데 이러한 데이터는 사용자의 상황을 인지하여 사용자가 원하는 서비스를 예측하는데 도움이 된다. [2]에서는 사용자 스마트폰에서 IoT 기기로부터 얻은 정보와 기존 사용자 정보를 사용하여 상황을 인식하고 사용자에게 상품을 추천하는 시스템을 제안하였다(그림 3). 음료수 자동 판매기를 IoT 기기로 상징할 경우, 상품의 존재 유무의 정보가 스



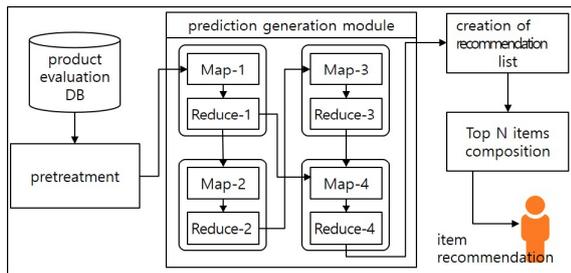
▶▶ 그림 3. 제안 시스템 구성도 [2]

마트폰으로 수집되고 서버에 있는 날씨, 계절, 시간, 사용자 정보(성별), 자동판매기의 위치 정보가 베이저안 네트워크의 입력값으로 사용되어 최종적으로 자동 판매기의 상품별 확률값을 계산하고 가장 높은 값을 가지는 상품을 추천한다.

GroupLens의 경우처럼 개인화 뉴스 시스템은 추천 시스템이 성공적으로 적용된 대표적인 예이다. IoT 환경에서는 IoT 기기들로부터의 정보를 활용하여 더욱 세밀한 뉴스 추천이 가능해 진다. 뉴스 기사의 선택은 독자의 평상시 관심사뿐 아니라 뉴스를 읽는 위치에도 영향을 받는다. 예를 들어, 금융 회사에 근무하는 독자는 비록 엔터테인먼트 뉴스를 선호하더라도 사무실에서는 비즈니스 기사를 읽는데 이것은 기사가 자신의 업무와 관련되어 있기 때문이다. [21]에서는 개인화된 뉴스 추천을 위해 사용자 선호에 위치를 통합하는 방법을 제안하였다. 사용자가 읽는 각 기사에는 GPS태그가 있어 뉴스 기사를 읽을 때마다 스마트폰에 의해 수집된다. 이 정보는 뉴스 기사 추천을 위한 단어 패턴과 함께 사용자의 지리적 패턴을 공동으로 모델링한다. 결과적으로 다른 위치에 대한 다른 사용자 선호도를 찾아 사용자 위치에 더 적합한 뉴스 기사를 추천하게 된다.

3.2 빅데이터 처리 기법을 적용한 추천 시스템

협업 필터링은 추천 시스템에서 가장 많이 사용되는 방식이지만 대규모의 데이터를 분석하거나 다룰 때 확장성의 문제가 더욱 심화되며, 아이템에 대한 상품평과 같은 구매자의 자세한 의사 표현이 반영되지 못하는 문제점을 갖고 있다. [22]에서는 데이터의 확장성 문제를 해결하기 위해 대규모 데이터 처리 분석을 위한 빅데이터 분산 처리 방식인 하둡(Hadoop) 맵리듀스(MapReduce) 방식을 활용하였다. 또한 사용자들의 평가값 이외에 상품에 남긴 추가 정보인 상품평과 같은 태그(Tag) 정보를 활용하는 방법을 제안하였다. 구체적으로, 아이템에 대한 사용자들의 선호도 변화를 적용하여 데이터를 전처리한 후 4단계의 맵리듀스를 거쳐 예측값을 출력하였다(그림 4). 유사도 계산에서 근접이웃을 지정하기 위해 태그 가중치를 적용하여 추천의 효율성과 정확도의 향상을 추구하였다.



▶▶ 그림 4. 제안 시스템 구성도 [22]

4. 맺음말

추천 시스템은 데이터마이닝 또는 머신러닝 분야에서 개발된 다양한 알고리즘들이 접목되어 진화해왔다. 최근 넷플릭스 프라이즈[23]에서 수상한 알고리즘에서 읽어볼 수 있는 경향은 하나의 탁월한 알고리즘이 아닌 기존 알고리즘들의 결합(ensemble)을 통한 성능 최적화를 시도하고 있다는 점이다. 여기에서 더 나아가, 다양한 리서치 커뮤니티가 추천 문제를 해결하기 위해 그들의 고유 기술들을 적용하고 있다. 그 대표적인 분야가 딥러닝이다. 학계와 산업계는 복잡한 문제를 해결할 수 있고 최첨단 결과를 제공하는 딥러닝을 다양한 응용 분야에 경쟁적으로 적용하고 있다[24]. 최근에는 딥러닝을 통해 추천 아키텍처가 혁신적으로 변화하고 있고 이에 따라 기존 모델의 장애를 극복하고 높은 추천 품질을 달성함으로써 사용자 만족도를 높일 수 있는 기회가 증가했다. 딥러닝은 비선형적이고 복잡한 사용자-아이템 관계를 효과적으로 포착하고 복잡한 추상화를 상위 계층의 데이터 표현 방식으로 체계화할 수 있다. 또한 문맥, 텍스트 및 시각 정보와 같이 풍부한 데이터 소스를 통해 데이터 자체의 복잡한 관계를 밝혀낼 수 있다. 향후 수년간은 딥러닝 기반의 추천 시스템에 대한 연구와 적용 그리고 구현이 학계와 산업계에서 활발히 진행될 것으로 예상된다.

4차 산업혁명의 이슈화와 함께 데이터 기반 의사 결정이 주목 받고 있다. 최근에는 하둡과 같은 다양한 분산처리 솔루션들이 제공됨으로써 소프트웨어/서비스 전문 회사가 아니더라도 쉽게 데이터를 분석할 수 있는 여건이 마련되고 있다. 하지만, 국내에는 데이터기반을 통한 추천 시스템 서비스의 제공이 여전히 미약하다. 딥러닝과 같은 새로운 분야와의 협업을 통한 혁신적인 연구 결과 도출과 산업계 적용이 활발해져 국내에서도 다양한 분야에 자동화된 추천 및 개인화 서비스가 정착되기를 기대

한다.

참고 문헌

- [1] Zhang, Shuai & Yao, Lina & Sun, Aixin. Deep Learning based Recommender System: A Survey and New Perspectives, ACM J. Comput. Cult. Herit., Vol. 1, No. 1, Article 35, 2017
- [2] 정수연, 김영국. IoT 환경에서의 베이지안 네트워크를 이용한 추천시스템. 한국컴퓨터정보학회 학술발표논문집, 24(2), 125-127, 2016
- [3] Sarwar, B., G. Karypis, J. Konstan and J. Riedl, "Item-based collaborative filtering recommendation algorithms," Proceeding of the 10th International Conference on World Wide Web, 2001, 285~295.
- [4] Rashid AM, Albert I, Cosley D, Lam SK, McNeer SM, Konstan JA et al. Getting to know you: learning new user preferences in recommender systems. In: Proceedings of the international conference on intelligent user interfaces, p.127-134, 2002.
- [5] Schafer JB, Konstan J, Riedl J. Recommender system in e-commerce. In: Proceedings of the 1st ACM conference on electronic commerce, p.158-166, 1999.
- [6] Resnick P, Varian HR. Recommender system's. Commun ACM, 40(3), 56-58, 1997.
- [7] 조윤호, 방정혜, "신상품 추천을 위한 사회연결망 분석의 활용", 지능정보연구, 15권 4호, 183~200, 2009.
- [8] 전병국, 안현철, "사용자 리뷰 마이닝을 결합한 협업 필터링 시스템: 스마트폰 앱 추천에의 응용", J Intell Inform Syst 2015 June:21(2), p.1-18.
- [9] 손지은, 김성범, 김현중, 조성준, "추천 시스템 기법 연구동향 분석", 대한산업공학회지 41(2), 185-208, 2015.
- [10] Isinkaye, F. O., Y. O. Folajimi, and B. A. Ojokoh. "Recommendation systems: Principles, methods and evaluation." Egyptian Informatics Journal16.3 (2015): 261-273.
- [11] Michael J. Pazzani, Daniel Billsus, Content-based recommendation systems, The adaptive web: methods and strategies of web personalization, Springer-Verlag, Berlin, Heidelberg, 2007.
- [12] Billsus D, Pazzani MJ. User modeling for adaptive news access. User Model User-adapted Interact 2000;10(2-3):147-180.
- [13] Mooney RJ, Roy L. Content-based book recommending using learning for text categorization. In: Proceedings of the fifth ACM conference on digital libraries. ACM; 2000. p. 195-204.

- [14] 입일, “R을 이용한 추천 시스템”, 카오스북, 2015
- [15] Schafer JB, Frankowski D, Herlocker J, Sen S. Collaborative filtering recommender systems. In: Brusilovsky P, Kobsa A, Nejdl W, editors. The Adaptive Web, LNCS 4321. Berlin Heidelberg (Germany): Springer; 2007. p. 291-324.
- [16] 조윤호, 김인환 (2010). 사회연결망분석과 인공지능망을 이용한 추천시스템 성능 예측. 지능정보연구, 16(4), 159-172.
- [17] Su X, Khoshgoftaar TM. A survey of collaborative filtering techniques. Adv Artif Intell 2009;4:19.
- [18] Konstan JA, Miller BN, Maltz D, Herlocker JL, Gordon LR, Riedl J. Applying collaborative filtering to usenet news. Commun ACM 1997;40(3):77-87.
- [19] Shardanand U, Maes P. Social information filtering: algorithms for automating “word of mouth”. In: Proceedings of the SIGCHI conference on human factors in computing systems. ACM Press/Addison-Wesley Publishing Co.; 1995. p. 210-217.
- [20] Linden G, Smith B, York J. Amazon.com recommendation: item-to-item collaborative filtering. IEEE Internet Comput 2003;7(1): 76-80.
- [21] Noh, Y., Oh, Y.-H., Park, S.-B.: A location-based personalized news recommendation. In: International Conference on Big Data and Smart Computing (BIGCOMP), pp. 99?104 (2014).
- [22] 윤소영, 윤성대 (2017). 빅 데이터 처리 기법을 적용한 추천 시스템에 관한 연구. 한국정보통신학회논문지, 21(6), 1183-1190.
- [23] Yehuda Koren. The bellkor solution to the netflix grand prize. Netflix prize documentation, 81, 2009.
- [24] Paul Covington, Jay Adams, and Emre Sargin. 2016. Deep neural networks for youtube recommendations. In sProceedings of the 10th ACM Conference on Recommender Systems. ACM, 191-198.

저 자 소 개

● 김 태 석(Tae-Suk Kim)



- 1998년 2월 : 한국과학기술원 산업경영학과 (공학사)
- 2000년 2월 : 한국과학기술원 산업공학 (공학석사)
- 2005년 2월 : 한국과학기술원 산업공학 (공학박사)

• 2005년~2007년 UIUC Post-Doc

• 2007년~2009년 UCR Post-Doc

• 2009년~2016년 삼성종합기술원 전문연구원

• 2016년~현재 배재대학교 경영학과 교수

<관심분야> : IT 경영, 데이터 마이닝, 빅데이터, 기계학습