



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0075602
(43) 공개일자 2022년06월08일

(51) 국제특허분류(Int. Cl.)
G06Q 30/06 (2012.01) G06N 3/08 (2006.01)
(52) CPC특허분류
G06Q 30/0631 (2013.01)
G06N 3/084 (2013.01)
(21) 출원번호 10-2020-0163874
(22) 출원일자 2020년11월30일
심사청구일자 2020년11월30일

(71) 출원인
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 발명자
신원용
서울특별시 서대문구 성산로 371, 102동 102호(연희동)
서창원
충청남도 예산군 예산읍 벚꽃로 175-30, 101동 1106호(발연휴먼시아아파트)
정경중
서울특별시 도봉구 노해로63다길 34(창동, 동아그린아파트)
(74) 대리인
민영준

전체 청구항 수 : 총 19 항

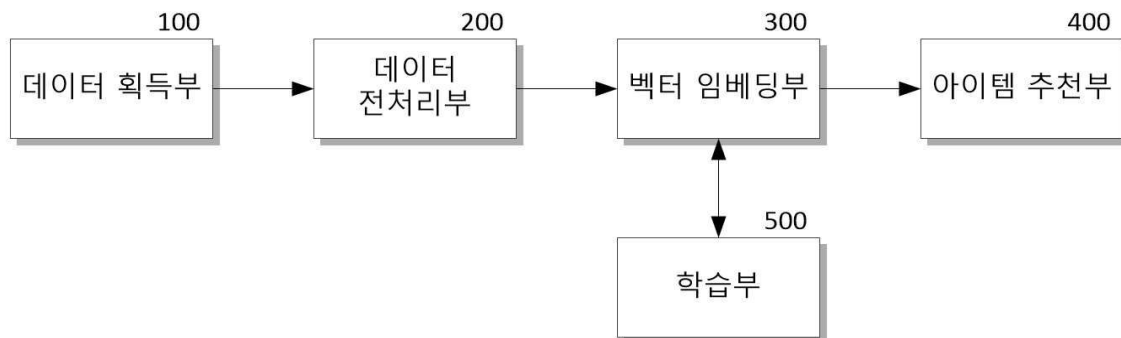
(54) 발명의 명칭 네트워크 임베딩을 이용한 다양성 강화 추천 장치 및 방법

(57) 요약

본 발명은 사용자와 아이템, 아이템이 포함되는 장르, 사용자의 아이템 이용 내역 및 평가 정보인 가중치가 포함된 사용자 아이템 데이터를 인가받아, 서로 대응하는 정보를 매칭하여 사용자 아이템 매칭 테이블을 획득하고, 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 가중치를 보정하며, 이

(뒷면에 계속)

대표도 - 도2



전 사용자와 매칭되지 않은 추가 아이템을 대응하는 사용자와 매칭하여 사용자 아이템 매칭 테이블에 추가하는 데이터 전처리부, 미리 학습된 인공 신경망으로 구현되어 사용자 아이템 매칭 테이블에서 서로 매칭된 사용자에게 아이템 각각을 벡터화하여 사용자 벡터와 아이템 벡터를 가상의 임베딩 공간 상에 배치하는 벡터 임베딩부 및 임베딩 공간 상에 배치된 사용자 벡터와 아이템 벡터 사이의 거리를 기반으로 추천 아이템을 선택하는 아이템 추천부를 포함하여, 방법은 명시적 피드백 정보인 선호도를 반영하여 아이템을 추천할 수 있도록 하여, 사용자 요구에 더욱 부합할 수 있는 아이템을 선별하여 추천할 수 있을 뿐만 아니라, 이전 소비하지 않았거나 많이 소비하지 않은 장르의 아이템도 추천될 수 있도록 하여 추천되는 아이템의 신규성과 다양성을 확보할 수 있는 추천 장치 및 방법을 제공할 수 있다.

이 발명을 지원한 국가연구개발사업

과제고유번호	1711119138
과제번호	2020-0-01463-001
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원(한국연구재단부설)
연구사업명	정보통신방송연구개발사업
연구과제명	질병 조기 진단을 위한 딥러닝 기반의 헬스케어 시스템 기술 연구
기 여 율	1/1
과제수행기관명	단국대학교 산학협력단
연구기간	2020.06.01 ~ 2021.05.31

명세서

청구범위

청구항 1

사용자와 아이템, 아이템이 포함되는 장르, 사용자의 아이템 이용 내역 및 평가 정보인 가중치가 포함된 사용자 아이템 데이터를 인가받아, 서로 대응하는 정보를 매칭하여 사용자 아이템 매칭 테이블을 획득하고, 상기 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 가중치를 보정하며, 이전 사용자와 매칭되지 않은 추가 아이템을 대응하는 사용자와 매칭하여 상기 사용자 아이템 매칭 테이블에 추가하는 데이터 전처리부;

미리 학습된 인공 신경망으로 구현되어 상기 사용자 아이템 매칭 테이블에서 서로 매칭된 사용자에게 아이템 각각을 벡터화하여 사용자 벡터와 아이템 벡터를 가상의 임베딩 공간 상에 배치하는 벡터 임베딩부; 및

상기 임베딩 공간 상에 배치된 사용자 벡터와 아이템 벡터 사이의 거리를 기반으로 추천 아이템을 선택하는 아이템 추천부를 포함하는 추천 장치.

청구항 2

제1항에 있어서, 상기 데이터 전처리부는

사용자 아이템 데이터에 포함된 사용자와 아이템, 장르 및 가중치 중 서로 대응하는 정보를 매칭시켜, 상기 사용자 아이템 매칭 테이블을 획득하는 관계 설정부;

상기 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 보정 가중치로 변환하는 오프셋 적용부; 및

이전 사용자와 매칭되지 않은 추가 아이템을 선택하여 사용자와 매칭하고, 매칭된 추가 아이템의 가중치를 할당하는 아이템 추가부를 포함하는 추천 장치.

청구항 3

제2항에 있어서, 상기 아이템 추가부는

사용자가 이전 이용하지 않은 장르를 탐색하여 탐색된 장르에서 기지정된 개수의 아이템을 선택하고, 선택된 아이템에 기지정된 제1 가중치를 할당하는 신규 장르 탐색부;

장르에 무관하게 사용자가 이전 이용하지 않은 아이템 중 기지정된 개수의 아이템을 탐색하여 선택하고, 선택된 아이템에 기지정된 제2 가중치를 할당하는 신규 아이템 탐색부; 및

선택된 아이템과 대응하여 할당된 제1 및 제2 가중치를 매칭하여, 상기 사용자 아이템 매칭 테이블에 삽입하는 아이템 삽입부를 포함하는 추천 장치.

청구항 4

제3항에 있어서, 상기 신규 장르 탐색부는

상기 사용자 아이템 매칭 테이블을 분석하여 사용자와 매칭되지 않은 장르를 탐색하고, 탐색된 장르에 포함된 아이템을 선택하는 신규 장르 선택부; 및

선택된 아이템에 기지정된 제1 가중치를 할당하는 제1 가중치 할당부를 포함하는 추천 장치.

청구항 5

제4항에 있어서, 상기 신규 아이템 탐색부는

상기 사용자 아이템 매칭 테이블을 분석하여 사용자와 매칭된 장르를 탐색하고, 탐색된 장르의 아이템 중 사용자와 매칭되지 않은 아이템을 탐색하여 선택하는 신규 아이템 선택부; 및

선택된 아이টে에 기지정된 제2 가중치를 할당하는 제2 가중치 할당부를 포함하는 추천 장치.

청구항 6

제5항에 있어서, 상기 오프셋 적용부는

상기 아이টে에 대해 기지정된 평가 범위의 중간값을 기준으로 기지정된 범위 이내의 임의의 값으로 오프셋값을 설정하고, 상기 가중치에서 상기 오프셋값을 차감하여 상기 보정 가중치를 획득하는 추천 장치.

청구항 7

제6항에 있어서, 상기 아이টে 추가부는

상기 제1 및 제2 가중치를 상기 보정 가중치의 범위 이내의 값에서 양의 값으로 할당하는 추천 장치.

청구항 8

제7항에 있어서, 상기 아이টে 추가부는 상기 제2 가중치는

상기 제1 가중치와 상기 제2 가중치를 서로 독립적으로 설정하는 추천 장치.

청구항 9

제8항에 있어서, 상기 아이টে 추천부는

상기 임베딩 공간 상에 배치된 사용자 벡터 각각을 중심으로 인접하여 배치된 기지정된 개수의 아이টে 벡터를 탐색하여, 추천 아이টে를 선택하는 추천 장치.

청구항 10

제9항에 있어서, 상기 추천 장치는

학습시에 추가되어 인공 신경망으로 구현된 상기 벡터 임베딩부를 학습시키는 학습부를 더 포함하고,

상기 학습부는 학습시에 사용자 벡터($f(u_i)$)와 아이টে 벡터($f(v_j)$) 및 보정 가중치($w_{i,j}^0$)를 이용하여 수학적

$$L(i, j) = -|w_{ij}^0| \log \sigma(\text{sign}(w_{ij}^0) f(u_i) \cdot f(v_j)) - \sum_{n=1}^K \mathbb{E}_{v_n \sim P_n(v)} [\log \sigma(-f(u_i) \cdot f(v_n))]$$

(여기서 σ 는 시그모이드 함수(sigmoid function)이고, $\text{sign}()$ 은 부호를 출력하는 사인 함수이며, $\mathbb{E}_{v_n \sim P_n(v)}$ 는 아이টে(v)의 확률 분포($p_n(v)$)에 기반하여 선택될 수 있는 아이টে(v_n)에 대한 크로스 엔트로피(cross entropy)를 나타내는 에너지 함수이다.)

에 따라 손실($L(i, j)$)을 계산하고, 계산된 손실($L(i, j)$)을 상기 벡터 임베딩부로 역전파하는 추천 장치.

청구항 11

사용자와 아이টে, 아이টে이 포함되는 장르, 사용자의 아이টে 이용 내역 및 평가 정보인 가중치가 포함된 사용자 아이টে 데이터를 인가받아, 서로 대응하는 정보를 매칭하여 사용자 아이টে 매칭 테이블을 획득하는 단계;

상기 사용자 아이টে 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 가중치를 보정하는 단계;

이전 사용자와 매칭되지 않은 추가 아이টে를 대응하는 사용자와 매칭하여 상기 사용자 아이টে 매칭 테이블에 추가하는 단계;

미리 학습된 인공 신경망으로 구현되어 상기 사용자 아이টে 매칭 테이블에서 서로 매칭된 사용자에게 아이টে 각각을 벡터화하여 사용자 벡터와 아이টে 벡터를 가상의 임베딩 공간 상에 배치하는 단계; 및

상기 임베딩 공간 상에 배치된 사용자 벡터와 아이টে 벡터 사이의 거리를 기반으로 추천 아이টে를 선택하는 단계를 포함하는 추천 방법.

청구항 12

제11항에 있어서, 상기 사용자 아이템 매칭 테이블에 추가하는 단계는

사용자가 이전 이용하지 않은 장르를 탐색하여 탐색된 장르에서 기지정된 개수의 아이템을 선택하고, 선택된 아이템에 기지정된 제1 가중치를 할당하는 단계;

장르에 무관하게 사용자가 이전 이용하지 않은 아이템 중 기지정된 개수의 아이템을 탐색하여 선택하고, 선택된 아이템에 기지정된 제2 가중치를 할당하는 단계; 및

선택된 아이템과 대응하여 할당된 제1 및 제2 가중치를 매칭하여, 상기 사용자 아이템 매칭 테이블에 삽입하는 단계를 포함하는 추천 방법.

청구항 13

제12항에 있어서, 상기 제1 가중치를 할당하는 단계는

상기 사용자 아이템 매칭 테이블을 분석하여 사용자와 매칭되지 않은 장르를 탐색하는 단계;

탐색된 장르에 포함된 아이템을 선택하는 단계; 및

선택된 아이템에 기지정된 제1 가중치를 할당하는 단계를 포함하는 추천 방법.

청구항 14

제13항에 있어서, 상기 제2 가중치를 할당하는 단계는

상기 사용자 아이템 매칭 테이블을 분석하여 사용자와 매칭된 장르를 탐색하는 단계;

탐색된 장르의 아이템 중 사용자와 매칭되지 않은 아이템을 탐색하여 선택하는 단계; 및

선택된 아이템에 기지정된 제2 가중치를 할당하는 단계를 포함하는 추천 방법.

청구항 15

제14항에 있어서, 상기 가중치를 보정하는 단계는

상기 아이템에 대해 기지정된 평가 범위의 중간값을 기준으로 기지정된 범위 이내의 임의의 값으로 오프셋값을 설정하고, 상기 가중치에서 상기 오프셋값을 차감하여 보정 가중치를 획득하는 추천 방법.

청구항 16

제15항에 있어서, 상기 사용자 아이템 매칭 테이블에 추가하는 단계는

상기 제1 및 제2 가중치를 상기 보정 가중치의 범위 이내의 값에서 양의 값으로 할당하는 추천 방법.

청구항 17

제16항에 있어서, 상기 아이템 추가부는

상기 제1 가중치와 상기 제2 가중치를 서로 독립적으로 설정하는 추천 방법.

청구항 18

제17항에 있어서, 상기 추천 아이템을 선택하는 단계는

상기 임베딩 공간 상에 배치된 사용자 벡터 각각을 중심으로 인접하여 배치된 기지정된 개수의 아이템 벡터를 탐색하여, 추천 아이템을 선택하는 추천 방법.

청구항 19

제18항에 있어서, 상기 추천 방법은

상기 인공 신경망을 학습시키기 위한 학습 단계를 더 포함하고,

상기 학습 단계는 사용자 벡터($f(u_i)$)와 아이템 벡터($f(v_j)$) 및 보정 가중치($w_{i,j}^0$)를 이용하여 수학적

$$L(i, j) = -|w_{ij}^0| \log \sigma(\text{sign}(w_{ij}^0) f(u_i) \cdot f(v_j)) - \sum_{n=1}^K \mathbb{E}_{v_n \sim P_n(v)} [\log \sigma(-f(u_i) \cdot f(v_n))]$$

(여기서 σ 는 시그모이드 함수(sigmoid function)이고, $\text{sign}()$ 은 부호를 출력하는 사인 함수이며, $\mathbb{E}_{v_n \sim P_n(v)}$ 는 아이템(v)의 확률 분포($p_n(v)$)에 기반하여 선택될 수 있는 아이템(v_n)에 대한 크로스 엔트로피(cross entropy)를 나타내는 에너지 함수이다.)

에 따라 손실($L(i, j)$)을 계산하는 단계; 및

계산된 손실($L(i, j)$)을 역전파하는 단계를 포함하는 추천 방법.

발명의 설명

기술 분야

[0001] 본 발명은 추천 장치 및 방법에 관한 것으로, 네트워크 임베딩을 이용한 다양성 강화 추천 장치 및 방법에 관한 것이다.

배경 기술

[0002] 점점 더 많은 콘텐츠 및 서비스가 온라인으로 소비됨에 따라 각종 추천 시스템이 온라인 사업의 효과적인 방법으로 떠올랐다. 특히 사용자와 아이템 간의 관계성을 중심으로 하는 개인 추천 시스템은 온라인 산업에서 중요한 이슈로 부각되고 있다.

[0003] 최근 딥러닝 기술을 활용한 추천 시스템은 네트워크를 이용하여 사용자와 아이템 간의 유사성까지 표현할 수 있도록 벡터화하는 네트워크 임베딩(Embedding) 방식을 통해 계속해서 발전하고 있다. 네트워크 임베딩 방식에서는 인공 신경망을 이용하여 사용자 개개인과 아이템의 정보가 각각 벡터화되어 가상의 임베딩 공간(Embedding Space)에 배치되며, 임베딩 공간 상에 배치된 사용자와 아이템 사이의 관계를 기반으로 사용자 개개인에 적합한 아이템을 추천한다.

[0004] 다만 기존의 네트워크 임베딩 방식에 대한 연구들은 아이템에 대한 사용자가 부여한 평점 등과 같은 명시적 피드백(explicit feedback) 정보보다, 주로 사용자가 아이템을 소비했는지 여부 등과 같이 소비자의 간접적 활동에 기반하는 암묵적 피드백(implicit feedback)을 활용한 알고리즘 개발에 집중되어 있다.

[0005] 도 1은 기존의 임베딩 방식에서 추천되는 아이템을 설명하기 위한 도면이다.

[0006] 도 1에서 (a)는 사용자 행동 테이블을 나타내고, (b)는 아이템 추천 테이블을 나타낸다. 사용자 행동 테이블은 도 1의 (a)에 나타난 바와 같이, 아이템 항목(Item)과 장르 항목(Genre) 및 선호도 항목(preference) 등이 포함될 수 있다.

[0007] 도 1의 (a)에서는 4개의 아이템(item1 ~ item4)에 대한 장르(A, B, D)와 선호도가 기록되어 있다. 이때 선호도 항목에는 선호(prefer) 또는 비선호(not prefer) 뿐만 아니라 특정 아이템(item4)이 사용자에게 의해 현재까지 소비된 적이 없음을 나타내는 비소비(not consume)가 기록될 수도 있다.

[0008] 사용자의 명시적 피드백인 선호도보다 아이템의 소비 내역을 기반으로 암묵적 피드백을 기반으로 추천하는 기존의 임베딩 방식에서는 (b)와 같이 동일 장르(A, B, D)의 유사 아이템(item1' ~ item4')의 추천 여부를 결정할 때, (a)와 같은 사용자 행동 테이블에서 사용자의 선호 또는 비선호보다 사용 내역을 우선하므로, 선호로 피드백된 제1 및 제2 유사 아이템(item1', item2')뿐만 아니라 비선호로 피드백된 제3 유사 아이템(item3') 또한 추천 아이템으로 선택한다. 따라서 사용자의 선호를 정확하게 반영하지 않고 아이템을 추천하는 문제가 있다.

[0009] 또한 사용자의 선호 여부를 판정할 수 없는 비소비 아이템(item4)이 포함된 장르(D)의 유사 아이템(item4')은 계속적으로 추천되지 않게 되어 추천되는 아이템의 신선함과 다양성이 떨어진다는 한계가 있다. 즉 사용자에게 다양하고 새로운 아이템을 추천할 수 없다는 한계가 있다.

선행기술문헌

특허문헌

[0010] (특허문헌 0001) 한국 공개 특허 제10-2020-0114969호 (2020.10.07 공개)

발명의 내용

해결하려는 과제

[0011] 본 발명의 목적은 사용자의 명시적 피드백 정보를 활용하여, 사용자의 선호를 반영하여 사용자에게 적합한 아이템을 정확하게 추천할 수 있는 추천 장치 및 방법을 제공하는데 있다.

[0012] 본 발명의 다른 목적은 사용자가 이전 소비하지 않았거나 많이 소비하지 않은 장르의 아이템도 추천될 수 있도록 하여 추천되는 아이템의 신규성과 다양성을 확보할 수 있는 추천 장치 및 방법을 제공하는데 있다.

과제의 해결 수단

[0013] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 따른 추천 장치 및 방법을 사용자와 아이템, 아이템이 포함되는 장르, 사용자의 아이템 이용 내역 및 평가 정보인 가중치가 포함된 사용자 아이템 데이터를 인가받아, 서로 대응하는 정보를 매칭하여 사용자 아이템 매칭 테이블을 획득하고, 상기 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 가중치를 보정하며, 이전 사용자와 매칭되지 않은 추가 아이템을 대응하는 사용자와 매칭하여 상기 사용자 아이템 매칭 테이블에 추가하는 데이터 전처리부; 미리 학습된 인공 신경망으로 구현되어 상기 사용자 아이템 매칭 테이블에서 서로 매칭된 사용자에게 아이템 각각을 벡터화하여 사용자 벡터와 아이템 벡터를 가상의 임베딩 공간 상에 배치하는 벡터 임베딩부; 및 상기 임베딩 공간 상에 배치된 사용자 벡터와 아이템 벡터 사이의 거리를 기반으로 추천 아이템을 선택하는 아이템 추천부를 포함한다.

[0014] 상기 데이터 전처리부는 사용자 아이템 데이터에 포함된 사용자와 아이템, 장르 및 가중치 중 서로 대응하는 정보를 매칭시켜, 상기 사용자 아이템 매칭 테이블을 획득하는 관계 설정부; 상기 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 보정 가중치로 변환하는 오프셋 적용부; 및 이전 사용자와 매칭되지 않은 추가 아이템을 선택하여 사용자와 매칭하고, 매칭된 추가 아이템의 가중치를 할당하는 아이템 추가부를 포함할 수 있다.

[0015] 상기 아이템 추가부는 사용자가 이전 이용하지 않은 장르를 탐색하여 탐색된 장르에서 기지정된 개수의 아이템을 선택하고, 선택된 아이템에 기지정된 제1 가중치를 할당하는 신규 장르 탐색부; 장르에 무관하게 사용자가 이전 이용하지 않은 아이템 중 기지정된 개수의 아이템을 탐색하여 선택하고, 선택된 아이템에 기지정된 제2 가중치를 할당하는 신규 아이템 탐색부; 및 선택된 아이템과 대응하여 할당된 제1 및 제2 가중치를 매칭하여, 상기 사용자 아이템 매칭 테이블에 삽입하는 아이템 삽입부를 포함할 수 있다.

[0016] 상기 신규 장르 탐색부는 상기 사용자 아이템 매칭 테이블을 분석하여 사용자와 매칭되지 않은 장르를 탐색하고, 탐색된 장르에 포함된 아이템을 선택하는 신규 장르 선택부; 및 선택된 아이템에 기지정된 제1 가중치를 할당하는 제1 가중치 할당부를 포함할 수 있다.

[0017] 상기 신규 아이템 탐색부는 상기 사용자 아이템 매칭 테이블을 분석하여 사용자와 매칭된 장르를 탐색하고, 탐색된 장르의 아이템 중 사용자와 매칭되지 않은 아이템을 탐색하여 선택하는 신규 아이템 선택부; 및 선택된 아이템에 기지정된 제2 가중치를 할당하는 제2 가중치 할당부를 포함할 수 있다.

[0018] 상기 오프셋 적용부는 상기 아이템에 대해 기지정된 평가 범위의 중간값을 기준으로 기지정된 범위 이내의 임의의 값으로 오프셋값을 설정하고, 상기 가중치에서 상기 오프셋값을 차감하여 상기 보정 가중치를 획득할 수 있다.

[0019] 상기 아이템 추가부는 상기 제1 및 제2 가중치를 상기 보정 가중치의 범위 이내의 값에서 양의 값으로 할당할 수 있다.

[0020] 상기 아이템 추가부는 상기 제2 가중치는 상기 제1 가중치와 상기 제2 가중치를 서로 독립적으로 설정할 수 있다.

다.

[0021] 상기 아이템 추천부는상기 임베딩 공간 상에 배치된 사용자 벡터 각각을 중심으로 인접하여 배치된 기지정된 개수의 아이템 벡터를 탐색하여, 추천 아이템을 선택할 수 있다.

[0022] 상기 추천 장치는 학습시에 추가되어 인공 신경망으로 구현된 상기 벡터 임베딩부를 학습시키는 학습부를 더 포함하고, 상기 학습부는 학습시에 사용자 벡터($f(u_i)$)와 아이템 벡터($f(v_j)$) 및 보정 가중치($w_{i,j}^0$)를 이용하여 수

[0023]

$$L(i,j) = -|w_{ij}^0| \log \sigma \left(\text{sign}(w_{ij}^0) f(u_i) \cdot f(v_j) \right) - \sum_{n=1}^K \mathbb{E}_{v_n \sim P_n(v)} [\log \sigma (-f(u_i) \cdot f(v_n))]$$

[0024] (여기서 σ 는 시그모이드 함수(sigmoid function)이고, $\text{sign}()$ 은 부호를 출력하는 사인 함수이며, $\mathbb{E}_{v_n \sim P_n(v)}$ 는 아이템(v)의 확률 분포($p_n(v)$)에 기반하여 선택될 수 있는 아이템(v_n)에 대한 크로스 엔트로피(cross entropy)를 나타내는 에너지 함수이다.)에 따라 손실($L(i,j)$)을 계산하고, 계산된 손실($L(i,j)$)을 상기 벡터 임베딩부로 역전파할 수 있다.

[0025] 상기 목적을 달성하기 위한 본 발명의 다른 실시예에 따른 사용자와 아이템, 아이템이 포함되는 장르, 사용자의 아이템 이용 내역 및 평가 정보인 가중치가 포함된 사용자 아이템 데이터를 인가받아, 서로 대응하는 정보를 매칭하여 사용자 아이템 매칭 테이블을 획득하는 단계; 상기 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값을 적용하여 가중치를 보정하는 단계; 이전 사용자와 매칭되지 않은 추가 아이템을 대응하는 사용자와 매칭하여 상기 사용자 아이템 매칭 테이블에 추가하는 단계; 미리 학습된 인공 신경망으로 구현되어 상기 사용자 아이템 매칭 테이블에서 서로 매칭된 사용자에게 아이템 각각을 벡터화하여 사용자 벡터와 아이템 벡터를 가상의 임베딩 공간 상에 배치하는 단계; 및 상기 임베딩 공간 상에 배치된 사용자 벡터와 아이템 벡터 사이의 거리를 기반으로 추천 아이템을 선택하는 단계를 포함한다.

발명의 효과

[0026] 따라서, 본 발명의 실시예에 따른 추천 장치 및 방법은 명시적 피드백 정보인 선호도를 반영하여 아이템을 추천할 수 있도록 하여, 사용자 요구에 더욱 부합할 수 있는 아이템을 선별하여 추천할 수 있다. 또한 이전 소비하지 않았거나 많이 소비하지 않은 장르의 아이템도 추천될 수 있도록 하여 추천되는 아이템의 신규성과 다양성을 확보할 수 있다.

도면의 간단한 설명

[0027] 도 1은 기존의 임베딩 방식에서 추천되는 아이템을 설명하기 위한 도면이다.

도 2는 본 발명의 일 실시예에 따른 네트워크 임베딩을 이용한 추천 장치의 개략적 구조를 나타낸다.

도 3은 도 2의 데이터 전처리부의 상세 구성의 일 예를 나타낸다.

도 4 및 도 5는 도 3의 데이터 전처리부의 동작을 설명하기 위한 도면이다.

도 6은 도 3의 아이템 추가부의 상세 구조의 일 예를 나타낸다.

도 7은 도 4의 아이템 추가부의 상세한 동작을 설명하기 위한 도면이다.

도 8은 도 2의 벡터 임베딩부와 아이템 추천부의 동작을 설명하기 위한 도면이다.

도 9는 다수의 사용자 각각에 대한 추천 아이템을 선택하는 개념을 설명하기 위한 도면이다.

도 10은 본 발명의 일 실시예에 따른 네트워크 임베딩을 이용한 추천 방법을 나타낸다.

발명을 실시하기 위한 구체적인 내용

[0028] 본 발명과 본 발명의 동작상의 이점 및 본 발명의 실시예에 의하여 달성되는 목적을 충분히 이해하기 위해서는 본 발명의 바람직한 실시예를 예시하는 첨부 도면 및 첨부 도면에 기재된 내용을 참조하여야만 한다.

[0029] 이하, 첨부한 도면을 참조하여 본 발명의 바람직한 실시예를 설명함으로써, 본 발명을 상세히 설명한다. 그러

나, 본 발명은 여러 가지 상이한 형태로 구현될 수 있으며, 설명하는 실시예에 한정되는 것이 아니다. 그리고, 본 발명을 명확하게 설명하기 위하여 설명과 관계없는 부분은 생략되며, 도면의 동일한 참조부호는 동일한 부재임을 나타낸다.

- [0030] 명세서 전체에서, 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라, 다른 구성요소를 더 포함할 수 있는 것을 의미한다. 또한, 명세서에 기재된 "...부", "...기", "모듈", "블록" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어나 소프트웨어 또는 하드웨어 및 소프트웨어의 결합으로 구현될 수 있다.
- [0031] 도 2는 본 발명의 일 실시예에 따른 네트워크 임베딩을 이용한 추천 장치의 개략적 구조를 나타내고, 도 3은 도 2의 데이터 전처리부의 상세 구성의 일 예를 나타내며, 도 4 및 도 5는 도 3의 데이터 전처리부의 동작을 설명하기 위한 도면이다.
- [0032] 도 2를 참조하면, 본 실시예에 따른 네트워크 임베딩을 이용한 추천 장치는 데이터 획득부(100), 데이터 전처리부(200), 벡터 임베딩부(300) 및 아이템 추천부(400)를 포함할 수 있다.
- [0033] 데이터 획득부(100)는 사용자 아이템 데이터를 수집하여 획득한다. 데이터 획득부(100)는 추천 장치를 이용하는 다수의 사용자에게 대한 정보와 추천 가능한 다수의 아이템에 대한 아이템 정보를 수집하여 사용자 아이템 데이터를 획득한다. 또한 사용자 아이템 데이터에는 각 사용자가 이용한 아이템 이용 내역과 사용자가 이용한 아이템에 대해 평가한 평가 정보를 함께 포함될 수 있으며, 각 아이템이 포함되는 장르(또는 카테고리라고도 함)에 대한 정보도 포함될 수 있다.
- [0034] 데이터 전처리부(200)는 데이터 획득부(100)에서 획득된 사용자 아이템 데이터를 기지정된 방식으로 전처리한다. 데이터 전처리부(200)는 후술하는 벡터 임베딩부(300)가 사용자의 아이템에 대한 선호도를 반영하여 임베딩 공간 상에 다수의 사용자와 다수의 아이템을 위치시키고, 사용자가 이용한적이 없는 아이템을 임베딩 공간 상에 위치시킬 수 있도록 사용자 아이템 데이터를 전처리한다.
- [0035] 데이터 전처리부(200)는 관계 설정부(210), 오프셋 적용부(220) 및 아이템 추가부(230)를 포함할 수 있다.
- [0036] 관계 설정부(210)는 데이터 획득부(100)에서 획득된 사용자 아이템 데이터를 기반으로 다수의 사용자와 다수의 아이템 사이의 관계를 설정한다. 관계 설정부(210)는 데이터 획득부(100)에서 획득된 사용자 정보와 아이템 정보, 이용 내역, 평가 정보 및 장르 정보를 인가받아 서로 대응하는 사용자 정보와 아이템 정보, 이용 내역, 평가 정보 및 장르 정보를 서로 매칭시켜 사용자 아이템 매칭 테이블을 획득할 수 있다.
- [0037] 일 예로 관계 설정부(210)는 도 4의 (a)에 도시된 바와 같이, 서로 대응하는 사용자 정보(user)와 아이템 정보(item), 장르 정보(genre) 및 평가 정보(rating)가 매칭되어 기록된 사용자 아이템 매칭 테이블을 획득할 수 있다.
- [0038] 여기서 사용자 아이템 매칭 테이블을 사용자와 아이템에 대한 이분 그래프(bipartite graph)로 표현하면, 도 5의 (a)와 같이 이분 그래프($G = (U, V)$)는 사용자($U = [u_1, u_2, \dots, u_n]$)와 아이템($V = [v_1, v_2, \dots, v_k]$) 및 사용자(U)와 아이템(V) 사이의 연관 수준을 나타내는 가중치(W)를 포함하는 형식으로 나타낼 수 있다. 여기서 가중치(W)는 평가 정보 항목의 평가치에 대응하는 값으로 획득될 수 있다. 여기서 임의의 사용자(u_i)의 특정 아이템(v_j)에 대한 가중치는 $w_{i,j}$ 와 같이 표시된다.
- [0039] 오프셋 적용부(220)는 관계 설정부(210)에서 획득된 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값(w_o)을 적용하여 가중치를 보정한다. 여기서 오프셋 적용부(220)가 오프셋값(w_o)을 적용하여 가중치를 보정하는 것은 사용자의 아이템에 대한 선호 또는 비선호를 부호(sign)로 명확하게 구분할 수 있도록 하기 위함이다.
- [0040] 일반적으로 온라인 상의 대부분의 아이템에 대한 평가는 양의 정수 범위내에서 부여되도록 설정된다. 이와 같이 평가치가 양의 정수 범위에서 부여되면, 아이템에 대한 평가 자체는 이루어지지만, 사용자의 해당 아이템에 대한 선호 또는 비선호가 명확하게 부각되지 않는다. 이에 본 실시예에서는 사용자의 아이템에 대한 선호 또는 비선호가 부호로 명확하게 표현될 수 있도록 가중치(W)에서 오프셋값(w_o)을 차감하여, 가중치(W)를 보정 가중치(W^o)로 변환한다.
- [0041] 도 4의 (b)와 도 5의 (b)에 도시된 바와 같이, 오프셋 적용부(220)에 의해 가중치(W)가 보정 가중치(W^o)로 보정

되면, 사용자의 명시적 피드백인 평가 결과에 따른 아이템에 대한 선호도가 양 또는 음의 값의 형태로 명확하게 나타나게 된다.

- [0042] 오프셋값(w_0)은 일 예로 평가 범위의 중간값에 대응하는 값으로 설정될 수 있다. 이는 평가 범위의 중간값이 사용자의 특정 아이템에 대한 선호 또는 비선호를 구분할 수 있는 기준이 될 수 있기 때문이다. 다만 평가 범위에 따라서 중간값이 모든 평가치에 대해 선호 또는 비선호를 구분할 수 없는 경우도 발생한다. 일 예로 1 ~ 5의 평가 범위로 부여될 수 있는 평가치에서, 중간값은 3이다. 따라서 오프셋값이 중간값인 3으로 설정되는 경우, 3의 평가치를 부여받은 아이템은 사용자의 선호 또는 비선호로 판별되기 어렵다. 이러한 모호성을 제거하기 위해, 오프셋값은 평가 범위의 중간값에 대응하는 다른 값으로 설정될 수 있으며, 여기서는 일 예로 3.5로 설정된 오프셋값을 차감하여 보정 가중치(w^0)를 획득한 경우를 도시하였다.
- [0043] 오프셋 적용부(220)는 이후, 각 사용자와 아이템에 사이의 관계 가중치를 기반으로 사용자의 선호도가 반영된 아이템을 정확하게 추천할 수 있도록 하기 위해 구비된다.
- [0044] 한편, 아이템 추가부(230)는 가중치(w)가 보정 가중치(w^0)로 보정된 사용자 아이템 매칭 테이블을 인가받아, 사용자와 매칭되지 않은 아이템을 사용자와 매칭하고 가중치를 부여한다. 이는 기존에 사용자가 이용한 경험에 없는 아이템이 사용자에게 추천될 수 있도록 하여, 사용자가 신선함과 다양함을 느낄 수 있도록 하기 위함이다.
- [0045] 이에 아이템 추가부(230)는 사용자가 포함된 아이템을 전혀 이용한 적이 없는 완전히 신규한 장르의 아이템을 선택하여 사용자와 매칭시킬 수 있다. 또한 아이템 추가부(230)는 장르에 무관하게 사용자가 이전 이용한 내역이 없는 아이템을 선택하여 사용자 아이템 매칭 테이블에 추가하고, 추가된 아이템을 사용자와 매칭시킬 수 있다. 이때 아이템 추가부(230)는 신규한 장르의 아이템과 이용 내역이 없는 아이템을 각각 탐색하고, 탐색된 아이템 중 기지정된 개수의 아이템을 랜덤하게 선택할 수 있다.
- [0046] 도 4의 (c)에서는 제1 및 제2 사용자(u_1, u_2) 각각이 이전 이용하지 않은 신규 장르(B, (C,D))의 아이템으로 제2 아이템(v_4)과 제4 아이템(v_4)이 선택되고, 이전 이용한 장르(D, F)에서 새로운 아이템으로 제4 아이템(v_4)과 제5 아이템(v_5)이 선택되어 추가된 경우를 도시하였다.
- [0047] 그리고 도 5의 (c)는 추가된 아이템에 따라 각 사용자(u_1, u_2)와 추가된 아이템 사이의 관계를 나타내는 예지가 점선 형태로 추가된 양분 그래프를 나타낸다.
- [0048] 다만 아이템 추가부(230)가 단순히 아이템을 추가하고 사용자와 매칭시키기만 한다면, 평가치가 존재하지 않아 추가된 아이템이 사용자에게 추천될 가능성이 매우 낮다. 이에 아이템 추가부(230)는 추가된 아이템에 대해 기지정된 가중치(λ)를 할당할 수 있다. 특히 아이템 추가부(230)는 사용자가 이용한 적이 없는 신규한 장르의 아이템과 장르에 무관하게 사용자가 이용한 내역이 없는 아이템에 대해 서로 다른 가중치(λ_1, λ_2)를 할당하여 추가되는 아이템의 추천 가능성을 차별화할 수 있다.
- [0049] 도 6은 도 3의 아이템 추가부의 상세 구조의 일 예를 나타내고, 도 7은 도 4의 아이템 추가부의 상세한 동작을 설명하기 위한 도면이다.
- [0050] 도 6을 참조하면, 아이템 추가부(230)는 신규 장르 탐색부(231)와 신규 아이템 탐색부(232) 및 아이템 삽입부(233)를 포함할 수 있다.
- [0051] 신규 장르 탐색부(231)와 신규 아이템 탐색부(232)는 사용자 아이템 매칭 테이블을 분석하여, 각각의 사용자가 이전 이용하지 않은 아이템, 즉 사용자 아이템 매칭 테이블에 매칭되지 않은 아이템을 탐색하여 획득한다. 신규 장르 탐색부(231)는 신규 장르 선택부(2311)와 제1 가중치 할당부(2312)를 포함하고, 신규 아이템 탐색부(232)는 신규 아이템 선택부(2321)와 제2 가중치 할당부(2322)를 포함할 수 있다.
- [0052] 우선 신규 장르 탐색부(231)의 신규 장르 선택부(2311)는 도 7의 (a)와 같이 사용자 아이템 매칭 테이블을 사용자와 매칭되지 않은, 즉 사용자가 이용한 내역이 없는 장르를 탐색하고, 도 7의 (b)와 같이 탐색된 장르에 포함된 아이템을 선택한다. 이때, 신규 장르 선택부(2311)는 탐색된 장르의 다수의 아이템 중 기지정된 개수의 아이템을 랜덤하게 선택할 수 있다. 그리고 제1 가중치 할당부(2312)는 선택된 아이템에 제1 가중치(λ_1)를 할당한다.
- [0053] 한편, 신규 아이템 탐색부(232)의 신규 아이템 선택부(2321)는 사용자 아이템 매칭 테이블을 분석하여, 장르에

무관하게 사용자와 매칭되지 않은 아이템을 도 7의 (c)와 같이 선택한다. 신규 아이템 선택부(2321) 또한 탐색된 장르의 다수의 아이템 중 기지정된 개수의 아이템을 랜덤하게 선택할 수 있다. 그리고 제2 가중치 할당부(2322)는 선택된 아이템에 제2 가중치(λ_2)를 할당한다. 이때, 제1 가중치(λ_1)와 제2 가중치(λ_2)는 다양하게 설정될 수 있으나, 오프셋값에 의해 보정된 가중치(w^0)의 범위 내의 값으로 할당된다. 여기서 제1 가중치(λ_1)와 제2 가중치(λ_2)는 서로 독립적인 값으로 개별적으로 설정될 수 있다.

- [0054] 아이템 삽입부(233)는 도 7의 (d)에 도시된 바와 같이, 신규 장르 탐색부(231)와 신규 아이템 탐색부(232)에서 선택된 아이템들을 사용자와 매칭하여, 사용자 아이템 매칭 테이블에 삽입한다.
- [0055] 도 8은 도 2의 벡터 임베딩부와 아이템 추천부의 동작을 설명하기 위한 도면이고, 도 9는 다수의 사용자 각각에 대한 추천 아이템을 선택하는 개념을 설명하기 위한 도면이다.
- [0056] 도 2 및 도 8을 참조하면, 벡터 임베딩부(300)는 데이터 전처리부(200)에서 전처리된 사용자 아이템 매칭 테이블을 인가받아, 사용자 아이템 매칭 테이블에 포함된 사용자(U)와 아이템(V) 및 가중치(w^0)를 기반으로 사용자(U)와 아이템(V)을 벡터화하여 가상의 임베딩 공간에 위치시킨다.
- [0057] 벡터 임베딩부(300)는 미리 학습된 인공 신경망으로 구현되어 도 8의 (a)와 같이 전처리된 사용자 아이템 매칭 테이블이 인가되면, 도 8의 (b)에 도시된 바와 같이, 학습된 방식에 따라 사용자(U)와 아이템(V)을 벡터화하고, 벡터화된 사용자 벡터($f(U)$)와 아이템 벡터($f(V)$)를 임베딩 공간에 배치한다.
- [0058] 아이템 추천부(400)는 임베딩 공간에 배치된 다수의 사용자 벡터($f(U)$)와 다수의 아이템 벡터($f(V)$) 사이의 관계에 따라 각 사용자에게 대응하는 아이템을 선택하여 추천한다.
- [0059] 아이템 추천부(400)는 도 8의 (b)에 도시된 바와 같이, 임베딩 공간 상에서 각 사용자 벡터($f(u_i)$)를 중심으로 가까운 위치에 배치된 기지정된 개수의 아이템 벡터($f(v_j)$)를 선택하여, 도 8의 (c)와 같이, 다수의 아이템 각각의 사용자 추천 여부를 결정할 수 있다. 도 9에서는 각 사용자 벡터($f(u_i)$)를 중심으로 인접하여 위치하는 3개씩의 아이템 벡터($f(v_j)$)를 선택하여 추천하는 경우를 도시하였다.
- [0060] 경우에 따라서 아이템 추천부(400)는 다수의 사용자 벡터($f(u_i)$) 각각을 중심으로 기지정된 거리 이내에 위치하는 아이템 벡터($f(v_j)$)를 선택하여, 사용자에게 추천하도록 구성될 수도 있다.
- [0061] 한편, 벡터 임베딩부(300)가 인공 신경망으로 구현됨에 따라 추천 장치를 실제 이용하기 전에 벡터 임베딩부(300)를 학습시킬 필요가 있다. 이에 본 실시예의 추천 장치는 벡터 임베딩부(300)의 학습을 위한 학습부(500)를 더 포함할 수 있다. 여기서 학습부(500)는 벡터 임베딩부(300)의 학습 시에만 추가되어 이용되고, 추천 장치가 실제 이용되는 경우에는 제거될 수 있다.
- [0062] 학습부(500)는 임베딩 공간 상에 배치된 사용자 벡터($f(u_i)$)와 아이템 벡터($f(v_j)$) 및 보정 가중치($w_{i,j}^0$)를 이용하여 수학적 식 1에 따라 손실($L(i,j)$)을 계산할 수 있다.

수학적 식 1

$$L(i,j) = -|w_{ij}^0| \log \sigma(\text{sign}(w_{ij}^0) f(u_i) \cdot f(v_j)) - \sum_{n=1}^K \mathbb{E}_{v_n \sim P_n(v)} [\log \sigma(-f(u_i) \cdot f(v_n))]$$

[0063]

[0064] 여기서 σ 는 시그모이드 함수(sigmoid function)이고, $\text{sign}()$ 은 부호를 출력하는 사인 함수이며, $\mathbb{E}_{v_n \sim P_n(v)}$ 는 아이템(v)의 이분 그래프 내 속성과 관계된 확률 분포($P_n(v)$)에 기반하여 선택될 수 있는 아이템(v_n)에 대한 크로스 엔트로피(cross entropy)를 나타내는 에너지 함수이다.

[0065] 수학적 식 1에서 $\text{sign}(w_{ij}^0)$ 는 사용자 벡터($f(u_i)$)와 아이템 벡터($f(v_j)$) 사이의 유사도 또는 비유사도를 부호로

나타내기 위한 함수로서, $-|w_{ij}^o| \log \sigma(\text{sign}(w_{ij}^o) f(u_i) \cdot f(v_j))$ 는 $\text{sign}(w_{ij}^o)$ 에 따라 사용자 벡터($f(u_i)$)와 아이템 벡터($f(v_j)$) 사이의 유사도 또는 비유사도를 최대화하기 위한 항목이며,

$$\sum_{n=1}^K \mathbb{E}_{v_n \sim P_n(v)} [\log \sigma(-f(u_i) \cdot f(v_n))]$$

은 비유사도를 최대화하기 위한 항목이다.

- [0066] 학습부(500)는 수식식 1에 따라 손실($L(i, j)$)이 계산되면, 계산된 손실 ($L(i, j)$)을 벡터 임베딩부(300)로 역전파하여, 벡터 임베딩부(300)를 학습시킬 수 있다.
- [0067] 결과적으로 본 실시예에 따른 네트워크 임베딩을 이용한 추천 장치는 다수의 사용자와 다수의 아이템 사이의 관계를 평가치를 기반으로 선호 또는 비선호로 구분하여 사용자에게 아이템을 추천하므로, 사용자가 선호하는 취향의 아이템을 정확하게 추천할 수 있다. 또한 사용자의 기존 아이템 이용 내역을 기반으로 신규 장르와 기존 장르에 포함되는 아이템을 구분하여 추가로 추천할 수 있어 사용자에게 아이템 추천의 신선함과 다양성을 제공할 수 있다.
- [0068] 도 10은 본 발명의 일 실시예에 따른 네트워크 임베딩을 이용한 추천 방법을 나타낸다.
- [0069] 도 2 내지 도 9를 참조하여, 도 10의 네트워크 임베딩을 이용한 추천 방법을 설명하면, 우선 사용자 아이템 데이터를 수집하여 획득한다(S10). 여기서 수집되는 사용자 아이템 데이터에는 사용자 정보와 아이템 정보, 장르, 아이템 이용 내역 및 평가 정보(가중치)가 포함될 수 있다.
- [0070] 사용자 아이템 데이터가 획득되면, 획득된 사용자 아이템을 전처리한다(S20).
- [0071] 전처리 단계에서는 먼저 획득된 사용자 아이템 데이터를 기반으로 다수의 사용자와 다수의 아이템 사이의 관계를 설정하여 사용자 아이템 매칭 테이블을 획득한다(S21). 사용자 아이템 매칭 테이블은 사용자 아이템 데이터에 포함된 사용자(U)와 아이템(V), 장르 및 가중치 중 서로 대응하는 정보를 매칭하여 획득할 수 있다.
- [0072] 사용자 아이템 매칭 테이블이 획득되면, 사용자 아이템 매칭 테이블에서 다수의 가중치 각각 대해 기지정된 오프셋값(w_o)을 적용하여 가중치를 보정한다(S22).
- [0073] 그리고 이전 사용자와 매칭되지 않은 추가 아이템을 선택하여 사용자와 매칭한다(S23). 이때, 추가되는 아이템은 사용자가 이전 이용하지 않은 장르의 아이템과 이전 이용한 장르에서 이용하지 않은 아이템으로 구분되어 선택될 수 있다.
- [0074] 추가 아이템이 선택되어 사용자와 매칭되면, 선택된 추가 아이템에 대한 가중치(λ)를 부여한다. 이때, 선택된 추가 아이템에 대한 가중치는 이전 이용하지 않은 장르에서 추가된 아이템과 이전 이용한 장르에서 추가된 아이템을 구분하여 서로 다른 가중치(λ_1, λ_2)로 할당될 수 있다.
- [0075] 추가 아이템에 대한 가중치(λ_1, λ_2)가 부여되면, 가중치가 부여된 추가 아이템을 사용자 아이템 매칭 테이블에 삽입한다(S25).
- [0076] 그리고 미리 학습된 인공 신경망에 사용자 아이템 매칭 테이블을 입력으로 인가하여, 사용자(U)와 아이템(V)을 각각 벡터화하고, 벡터화된 사용자 벡터($f(U)$)와 아이템 벡터($f(V)$)를 가상의 임베딩 공간 상에 위치시킨다(S30).
- [0077] 사용자 벡터($f(U)$)와 아이템 벡터($f(V)$)가 임베딩 공간 상에 배치되면, 임베딩 공간 상의 각 사용자 벡터($f(u_i)$)와 아이템 벡터($f(v_j)$) 사이의 거리를 기반으로 사용자별 추천 아이템을 기지정된 방식으로 탐색한다(S40). 그리고 탐색된 아이템(v_j)을 해당 사용자(u_i)에게 추천한다(S50).
- [0078] 또한 도시하지 않았으나, 인공 신경망을 학습시키기 위한 학습 단계를
- [0079] 본 발명에 따른 방법은 컴퓨터에서 실행시키기 위한 매체에 저장된 컴퓨터 프로그램으로 구현될 수 있다. 여기서 컴퓨터 판독가능 매체는 컴퓨터에 의해 액세스 될 수 있는 임의의 가용 매체일 수 있고, 또한 컴퓨터 저장 매체를 모두 포함할 수 있다. 컴퓨터 저장 매체는 컴퓨터 판독가능 명령어, 데이터 구조, 프로그램 모듈 또는 기타 데이터와 같은 정보의 저장을 위한 임의의 방법 또는 기술로 구현된 휘발성 및 비휘발성, 분리형 및 비분리형 매체를 모두 포함하며, ROM(판독 전용 메모리), RAM(랜덤 액세스 메모리), CD(컴팩트 디스크)-ROM, DVD(디

지털 비디오 디스크)-ROM, 자기 테이프, 플로피 디스크, 광데이터 저장장치 등을 포함할 수 있다.

[0080] 본 발명은 도면에 도시된 실시예를 참고로 설명되었으나 이는 예시적인 것에 불과하며, 본 기술 분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시예가 가능하다는 점을 이해할 것이다.


[0081] 따라서, 본 발명의 진정한 기술적 보호 범위는 첨부된 청구범위의 기술적 사상에 의해 정해져야 할 것이다.

부호의 설명

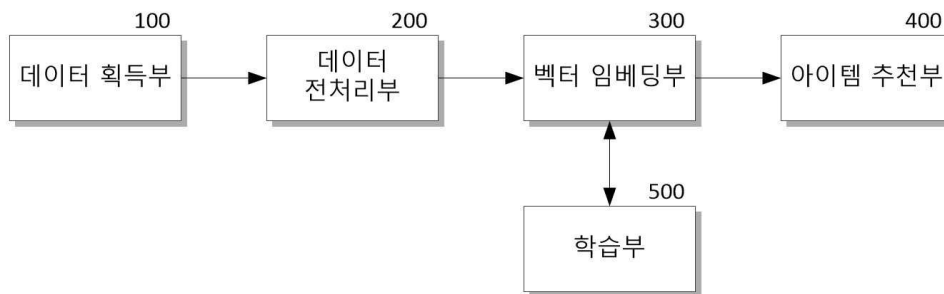
[0082] 100: 데이터 획득부 200: 데이터 전처리부
210: 관계 설정부 220: 오프셋 적용부
230: 아이템 추가부 231: 신규 장르 탐색부
232: 신규 아이템 탐색부 233: 아이템 삽입부
2311: 신규 장르 선택부 2312: 제1 가중치 할당부
2321: 신규 아이템 선택부 2322: 제2 가중치 할당부
300: 벡터 임베딩부 400: 아이템 추천부
500: 학습부

도면


도면1



도면2



도면3



도면4

user	item	genre	weight
u_1	v_1	A	5
u_1	v_3	D	1
u_2	v_2	B	5
u_2	v_3	E,F	2

(a)


user	item	genre	weight
u_1	v_1	A	1.5
u_1	v_3	D	-2.5
u_2	v_2	B	1.5
u_2	v_3	E,F	-1.5

(b)


user	item	genre	weight
u_1	v_1	A	1.5
u_1	v_3	D	-2.5
u_2	v_2	B	1.5
u_2	v_3	E,F	-1.5
u_1	v_2	B	λ_1
u_1	v_4	C,D	λ_2
u_2	v_4	C,D	λ_1
u_2	v_5	A,F	λ_2

(c)


도면5



(a)

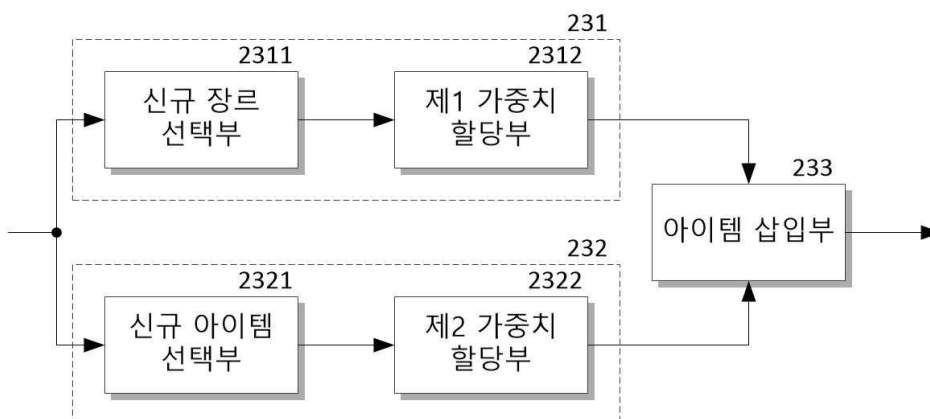


(b)




(c)

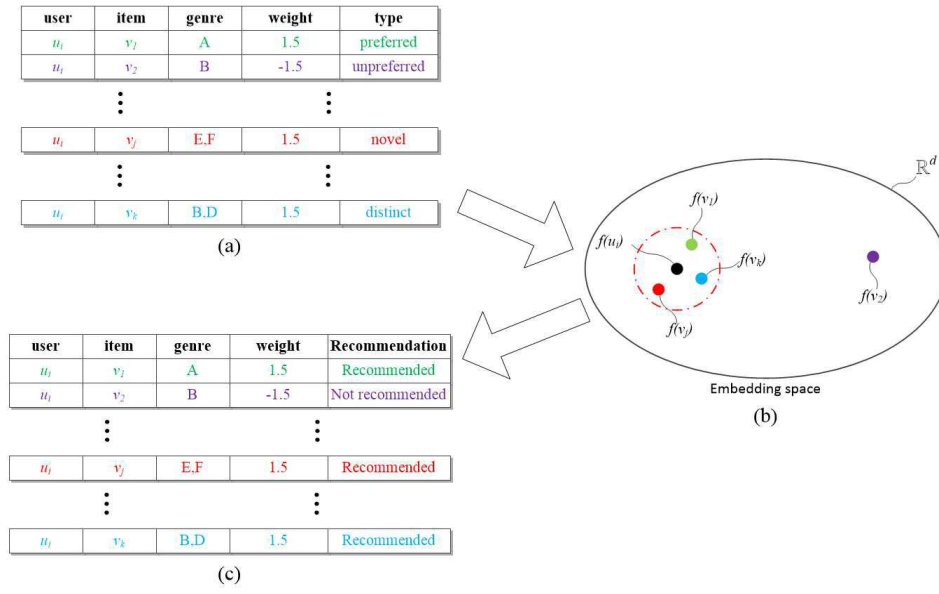
도면6




도면7



도면8



도면9



도면10

