



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0069578
(43) 공개일자 2023년05월19일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) G06N 3/04 (2023.01)
(52) CPC특허분류
G06N 3/084 (2023.01)
G06N 3/04 (2023.01)
(21) 출원번호 10-2021-0155724
(22) 출원일자 2021년11월12일
심사청구일자 2021년11월12일

(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

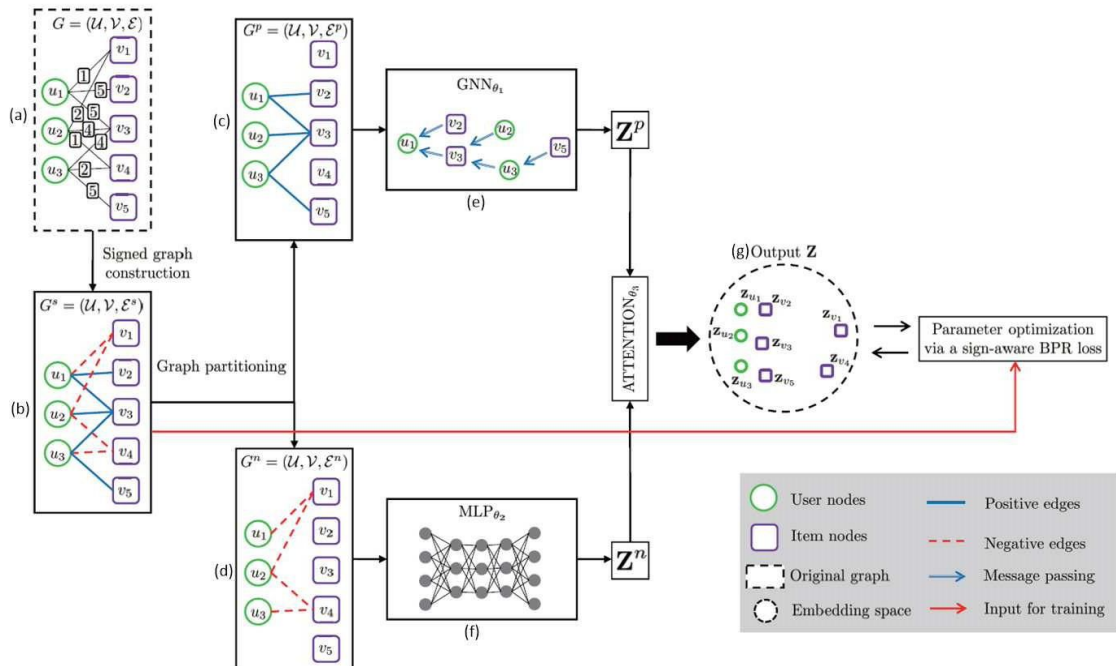
(54) 발명의 명칭 그래프 신경망을 이용한 부호 인지 추천 장치 및 방법

(57) 요약

본 발명은 다수의 사용자 각각에 대응하는 다수의 사용자 노드와 다수의 아이템 각각에 대응하는 다수의 아이템 노드 및 다수의 사용자의 각 아이템에 대한 평가 점수가 가중치로 가중되어 사용자 노드와 아이템 노드를 잇는 다수의 엣지로 구성된 이분 그래프에서 가중치에 따라 다수의 엣지를 포지티브 엣지와 네거티브 엣지로 구분하고

(뒷면에 계속)

대표도



분할하여, 포지티브 엣지를 갖는 포지티브 그래프와 네거티브 엣지를 갖는 네거티브 그래프를 생성하는 그래프 생성부, 인공 신경망으로 구현되어, 미리 학습된 방식에 따라 신경망 연산을 수행하여 포지티브 그래프와 네거티브 그래프 각각을 벡터화하여 포지티브 임베딩 벡터와 네거티브 임베딩 벡터를 획득하고, 포지티브 임베딩 벡터와 네거티브 임베딩 벡터가 결합된 결합 임베딩 벡터를 획득함으로써, 가상의 공통 임베딩 공간에서 다수의 사용자 노드와 다수의 아이템 노드의 위치를 결정하는 임베딩부 및 임베딩 공간에서 다수의 사용자 노드 각각에 대한 다수의 아이템 노드 각각의 거리를 기반으로 각 사용자에게 아이템을 추천하는 추천부를 포함하여, 유사 사용자의 아이템들에 대한 선호도뿐만 아니라 비선호도를 고려하여, 사용자가 확실히 선호할 수 있는 아이템을 정확하게 추천할 수 있는 추천 장치 및 방법을 제공한다.

이 발명을 지원한 국가연구개발사업

| | |
|-------------|--|
| 과제고유번호 | 1711137771 |
| 과제번호 | 2021R1A2C3004345 |
| 부처명 | 과학기술정보통신부 |
| 과제관리(전문)기관명 | 한국연구재단 |
| 연구사업명 | 중견연구자지원사업 |
| 연구과제명 | 초불확실성 문제 해결을 위한 심층 네트워크 복구 방법 및 핵심 요소기술 개발 |
| 기 여 율 | 1/1 |
| 과제수행기관명 | 연세대학교 산학협력단 |
| 연구기간 | 2021.03.01 ~ 2022.02.28 |

명세서

청구범위

청구항 1

다수의 사용자 각각에 대응하는 다수의 사용자 노드와 다수의 아이템 각각에 대응하는 다수의 아이템 노드 및 다수의 사용자의 각 아이템에 대한 평가 점수가 가중치로 가중되어 사용자 노드와 아이템 노드를 잇는 다수의 엣지로 구성된 이분 그래프에서 상기 가중치에 따라 상기 다수의 엣지를 포지티브 엣지와 네거티브 엣지로 구분하고 분할하여, 상기 포지티브 엣지를 갖는 포지티브 그래프와 상기 네거티브 엣지를 갖는 네거티브 그래프를 생성하는 그래프 생성부;

인공 신경망으로 구현되어, 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 포지티브 그래프와 상기 네거티브 그래프 각각을 벡터화하여 포지티브 임베딩 벡터와 네거티브 임베딩 벡터를 획득하고, 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터가 결합된 결합 임베딩 벡터를 획득함으로써, 가상의 공통 임베딩 공간에서 상기 다수의 사용자 노드와 상기 다수의 아이템 노드의 위치를 결정하는 임베딩부; 및

상기 임베딩 공간에서 상기 다수의 사용자 노드 각각에 대한 상기 다수의 아이템 노드 각각의 거리를 기반으로 각 사용자에게 아이템을 추천하는 추천부를 포함하는 추천 장치.

청구항 2

제1항에 있어서, 상기 임베딩부는

상기 다수의 사용자의 상기 다수의 아이템에 대한 선호도를 나타내는 상기 포지티브 그래프를 인가받아 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 각각을 벡터화하여 상기 포지티브 임베딩 벡터를 획득하는 포지티브 임베딩부;

상기 다수의 사용자의 상기 다수의 아이템에 대한 비선호도를 나타내는 상기 네거티브 그래프를 인가받아 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 각각을 벡터화하여 네거티브 임베딩 벡터를 획득하는 네거티브 임베딩부; 및

미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터 각각에 대응하는 포지티브 중요도와 네거티브 중요도를 추정하고, 상기 포지티브 중요도와 상기 네거티브 중요도를 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터에 가중합하여 상기 결합 임베딩 벡터를 획득하는 통합 강조 임베딩부를 포함하는 추천 장치.

청구항 3

제2항에 있어서, 상기 포지티브 임베딩부는

GNN(Graph Neural Network)로 구현되고,

상기 네거티브 임베딩부는

MLP(Multi-layer Perceptron)로 구현되는 추천 장치.

청구항 4

제1항에 있어서, 상기 그래프 생성부는

상기 이분 그래프에서 다수의 엣지 각각의 가중치가 기지정된 기준 가중치 이상인지 판별하여, 기준 가중치 이상인 엣지를 상기 포지티브 엣지로 설정하고, 가중치가 상기 기준 가중치 미만인 엣지를 상기 네거티브 엣지로 설정하여 부호화된 엣지를 포함하는 부호 그래프를 획득하는 부호 그래프 획득부; 및

상기 부호 그래프를 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 및 상기 포지티브 엣지로 구성되는 상기 포지티브 그래프와 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 및 상기 네거티브 엣지로 구성되는 상기 네거티브 그래프로 분할하는 분할 그래프 획득부를 포함하는 추천 장치.

청구항 5

제4항에 있어서, 상기 기준 가중치는

상기 다수의 사용자의 각 아이টে에 대한 평가 점수의 중간값으로 설정되는 추천 장치.

청구항 6

제4항에 있어서, 상기 그래프 생성부는

상기 다수의 사용자가 다수의 아이টে에 대해 평가한 평가 점수가 포함된 평가 데이터를 인가받고, 상기 평가 데이터로부터 상기 다수의 사용자 각각에 대응하는 상기 다수의 사용자 노드와 상기 다수의 아이টে에 대응하는 상기 다수의 아이টে 노드 및 각 사용자의 각 아이টে에 대한 평가 여부에 따라 사용자 노드와 아이টে 노드를 잇는 다수의 엣지를 생성하고, 평가 점수를 생성된 엣지의 가중치로 설정하여 상기 이분 그래프를 획득하는 이분 그래프 획득부를 더 포함하는 추천 장치.

청구항 7

제2항에 있어서, 상기 추천 장치는

학습 시에 구비되어 인공 신경망으로 구현되는 상기 임베딩부를 학습시키는 부호 인지 학습부를 더 포함하고,

상기 부호 인지 학습부는

상기 이분 그래프의 엣지를 상기 포지티브 엣지와 상기 네거티브 엣지로 부호화한 부호화 그래프에서 다수의 사용자 노드 각각에 엣지로 연결된 아이টে 노드인 연관 아이টে 노드와 엣지로 연결되지 않은 아이টে 노드인 무연관 아이টে 노드로 구성되는 다수의 트리플렛 샘플을 획득하여 다수의 배치를 획득하고, 획득된 트리플렛 샘플에서 상기 연관 아이টে 노드의 부호에 따른 사용자 노드와 연관 아이টে 노드 및 무연관 아이টে 노드 각각에 대한 상기 공통 임베딩 공간에서의 관계로 계산되는 부호 인지 BPR 손실과 정규화에 따른 정규화 손실의 합으로 부호 인지 손실을 계산하여 역전파하는 추천 장치.

청구항 8

제7항에 있어서, 상기 부호 인지 학습부는

상기 트리플렛 샘플(u, i, j)에서 상기 사용자 노드(u)의 상기 연관 아이টে 노드(i) 및 상기 무연관 아이টে 노드(j) 각각에 대한 예측 선호도($\hat{r}_{ui}, \hat{r}_{uj}$)를 상기 결합 임베딩 벡터에서 상기 사용자 노드(u)에 대응하는 사용자 임베딩 벡터(z_u)와 상기 연관 아이টে 노드(i)에 대한 연관 임베딩 벡터(z_i) 사이의 내적 및 사용자 임베딩 벡터(z_u)와 상기 무연관 아이টে 노드(j)에 대한 무연관 임베딩 벡터(z_j) 사이의 내적으로 계산하고,

상기 사용자 노드(u)와 상기 연관 아이টে 노드(i)를 잇는 엣지의 가중치(w) 부호에 따라

수학식

$$\begin{aligned} &>_u(i, j, w) \\ &\triangleq \{(i, j, w) | \hat{r}_{ui} > \hat{r}_{uj} \text{ if } w > 0 \\ &\quad \text{and } -\hat{r}_{ui} > \hat{r}_{uj} \text{ otherwise}\} \end{aligned}$$

로 정의되는 삼항 관계($>_u$)를 기반으로, 삼항 관계($>_u$)에 따른 우도(likelihood)($p()$)를 수학식

$$p(>_u(i, j, w_{ui}^s) | \Theta) \triangleq \sigma(\text{sgn}(w_{ui}^s) \hat{r}_{ui} - \hat{r}_{uj})$$

(여기서 $\text{sgn}()$ 는 부호 함수이고, $\sigma()$ 는 $\sigma(x) = \frac{1}{1+\exp(-x)}$ 로 계산되는 시그모이드 함수, Θ 는 인공 신경망으로 구현되는 포지티브 임베딩부, 네거티브 임베딩부 및 통합 강조 임베딩부에서 학습에 의해 획득되는 모델 파라미터 집합)으로 계산하여, 수학식

$$\mathcal{L}_0 = - \sum_{(u,i,j) \in \mathcal{D}'_S} \log p(>_u(i, j, w_{ui}^s) | \Theta)$$

에 따라 상기 부호 인지 BPR 손실을 계산하는 추천 장치.

청구항 9

제8항에 있어서, 상기 부호 인지 학습부는

상기 부호 인지 손실을 수학식

$$\mathcal{L} = \mathcal{L}_0 + \lambda_{\text{reg}} \|\Theta\|^2$$

(여기서 $\|\cdot\|^2$ 는 L_2 정규화 함수이고, λ_{reg} 는 정규화 강도를 조절하기 위한 하이퍼파라미터)

에 따라 획득하여 역전파하는 추천 장치.

청구항 10

제1항에 있어서, 상기 추천부는

상기 공통 임베딩 공간에서 상기 다수의 사용자 노드 각각과 다수의 아이템 노드 사이의 거리를 계산하고, 상기 다수의 사용자 노드 각각에 대해 인접한 순서로 기지정된 개수의 아이템 노드를 선출하여, 각 사용자에게 아이템을 추천하는 추천 장치.

청구항 11

사용자에게 아이템을 추천하는 동작을 수행하는 추천 장치의 추천 방법에 있어서,

다수의 사용자 각각에 대응하는 다수의 사용자 노드와 다수의 아이템 각각에 대응하는 다수의 아이템 노드 및 다수의 사용자의 각 아이템에 대한 평가 점수가 가중치로 가중되어 사용자 노드와 아이템 노드를 잇는 다수의 엣지로 구성된 이분 그래프에서 상기 가중치에 따라 상기 다수의 엣지를 포지티브 엣지와 네거티브 엣지로 구분하고 분할하여, 상기 포지티브 엣지를 갖는 포지티브 그래프와 상기 네거티브 엣지를 갖는 네거티브 그래프로 분할된 그래프를 생성하는 단계;

미리 학습된 인공 신경망을 이용하여 상기 포지티브 그래프와 상기 네거티브 그래프 각각에 대해 신경망 연산을 수행하여 벡터화된 포지티브 임베딩 벡터와 네거티브 임베딩 벡터를 획득하고, 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터가 결합된 결합 임베딩 벡터를 획득함으로써, 가상의 공통 임베딩 공간에서 상기 다수의 사용자 노드와 상기 다수의 아이템 노드의 위치를 결정하여 임베딩하는 단계; 및

상기 임베딩 공간에서 상기 다수의 사용자 노드 각각에 대한 상기 다수의 아이템 노드 각각의 거리를 기반으로 각 사용자에게 아이템을 추천하는 단계를 포함하는 추천 방법.

청구항 12

제11항에 있어서, 상기 임베딩하는 단계는

상기 다수의 사용자의 상기 다수의 아이템에 대한 선호도를 나타내는 상기 포지티브 그래프를 인가받아 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 각각을 벡터화하여 상기 포지티브 임베딩 벡터를 획득하는 단계;

상기 다수의 사용자의 상기 다수의 아이템에 대한 비선호도를 나타내는 상기 네거티브 그래프를 인가받아 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 각각을 벡터화하여 네거티브 임베딩 벡터를 획득하는 단계; 및

미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터 각각에 대응하는 포지티브 중요도와 네거티브 중요도를 추정하고, 상기 포지티브 중요도와 상기 네거티브 중요도를 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터에 가중합하여 상기 결합 임베딩 벡터를 획득하는

단계를 포함하는 추천 방법.

청구항 13

제12항에 있어서, 상기 포지티브 임베딩 벡터를 획득하는 단계는

GNN(Graph Neural Network)를 이용하여 수행되고,

상기 네거티브 임베딩 벡터를 획득하는 단계는

MLP(Multi-layer Perceptron)를 이용하여 수행되는 추천 방법.

청구항 14

제11항에 있어서, 상기 분할된 그래프를 생성하는 단계는

상기 이분 그래프에서 다수의 엣지 각각의 가중치가 기설정된 기준 가중치 이상인지 판별하여, 기준 가중치 이상인 엣지를 상기 포지티브 엣지로 설정하고, 가중치가 상기 기준 가중치 미만인 엣지를 상기 네거티브 엣지로 설정하여 부호화된 엣지를 포함하는 부호 그래프를 획득하는 단계; 및

상기 부호 그래프를 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 및 상기 포지티브 엣지로 구성되는 상기 포지티브 그래프와 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 및 상기 네거티브 엣지로 구성되는 상기 네거티브 그래프로 분할하는 단계를 포함하는 추천 방법.

청구항 15

제14항에 있어서, 상기 기준 가중치는

상기 다수의 사용자의 각 아이템에 대한 평가 점수의 중간값으로 설정되는 추천 방법.

청구항 16

제14항에 있어서, 상기 분할된 그래프를 생성하는 단계는

부호 그래프를 획득하는 단계 이전, 상기 다수의 사용자가 다수의 아이템에 대해 평가한 평가 점수가 포함된 평가 데이터를 인가받고, 상기 평가 데이터로부터 상기 다수의 사용자 각각에 대응하는 상기 다수의 사용자 노드와 상기 다수의 아이템에 대응하는 상기 다수의 아이템 노드 및 각 사용자의 각 아이템에 대한 평가 여부에 따라 사용자 노드와 아이템 노드를 잇는 다수의 엣지를 생성하고, 평가 점수를 생성된 엣지의 가중치로 설정하여 상기 이분 그래프를 획득하는 단계를 더 포함하는 추천 방법.

청구항 17

제12항에 있어서, 상기 추천 방법은

상기 인공 신경망을 학습시키는 학습 단계를 더 포함하고,

상기 학습 단계는

상기 이분 그래프의 엣지를 상기 포지티브 엣지와 상기 네거티브 엣지로 부호화한 부호화 그래프에서 다수의 사용자 노드 각각에 엣지로 연결된 아이템 노드인 연관 아이템 노드와 엣지로 연결되지 않은 아이템 노드인 무연관 아이템 노드로 구성되는 다수의 트리플렛 샘플을 획득하여 다수의 배치로 획득하는 단계; 및

획득된 트리플렛 샘플에서 상기 연관 아이템 노드의 부호에 따른 사용자 노드와 연관 아이템 노드 및 무연관 아이템 노드 각각에 대한 상기 공통 임베딩 공간에서의 관계로 계산되는 부호 인지 BPR 손실과 정규화에 따른 정규화 손실의 합으로 부호 인지 손실을 계산하는 단계를 포함하는 추천 방법.

청구항 18

제17항에 있어서, 상기 부호 인지 손실을 계산하는 단계는

상기 트리플렛 샘플(u, i, j)에서 상기 사용자 노드(u)의 상기 연관 아이템 노드(i) 및 상기 무연관 아이템 노드(j) 각각에 대한 예측 선호도($\hat{r}_{ui}, \hat{r}_{uj}$)를 상기 결합 임베딩 벡터에서 상기 사용자 노드(u)에 대응하는 사

용자 임베딩 벡터(z_u)와 상기 연관 아이템 노드(i)에 대한 연관 임베딩 벡터(z_i) 사이의 내적 및 사용자 임베딩 벡터(z_u)와 상기 무연관 아이템 노드(j)에 대한 무연관 임베딩 벡터(z_j) 사이의 내적으로 계산하는 단계;

상기 사용자 노드(u)와 상기 연관 아이템 노드(i)를 잇는 엣지의 가중치(w) 부호에 따라 수학적식

$$\begin{aligned} & >_u(i, j, w) \\ & \triangleq \{(i, j, w) | \hat{r}_{ui} > \hat{r}_{uj} \text{ if } w > 0 \\ & \text{and } -\hat{r}_{ui} > \hat{r}_{uj} \text{ otherwise}\} \end{aligned}$$

로 정의되는 삼항 관계($>_u$)를 기반으로, 삼항 관계($>_u$)에 따른 우도(likelihood)($p()$)를 수학적식

$$p(>_u(i, j, w_{ui}^s) | \Theta) \triangleq \sigma(\text{sgn}(w_{ui}^s) \hat{r}_{ui} - \hat{r}_{uj})$$

(여기서 $\text{sgn}()$ 는 부호 함수이고, $\sigma(x) = \frac{1}{1+\exp(-x)}$ 로 계산되는 시그모이드 함수, Θ 는 인공 신경망으로 구현되는 포지티브 임베딩부, 네거티브 임베딩부 및 통합 강조 임베딩부에서 학습에 의해 획득되는 모델 파라미터 집합)으로 계산하여, 수학적식

$$\mathcal{L}_0 = - \sum_{(u, i, j) \in \mathcal{D}'_S} \log p(>_u(i, j, w_{ui}^s) | \Theta)$$

에 따라 상기 부호 인지 BPR 손실을 계산하는 단계; 및

상기 부호 인지 손실을 수학적식

$$\mathcal{L} = \mathcal{L}_0 + \lambda_{\text{reg}} \|\Theta\|^2$$

(여기서 $\|\cdot\|^2$ 는 L_2 정규화 함수이고, λ_{reg} 는 정규화 강도를 조절하기 위한 파라미터)

에 따라 획득하여 역전파하는 단계를 포함하는 추천 방법.

청구항 19

제11항에 있어서, 상기 아이템을 추천하는 단계는

상기 공통 임베딩 공간에서 상기 다수의 사용자 노드 각각과 다수의 아이템 노드 사이의 거리를 계산하는 단계; 및

상기 다수의 사용자 노드 각각에 대해 인접한 순서로 기지정된 개수의 아이템 노드를 선출하여, 각 사용자에게 아이템을 추천하는 단계를 포함하는 추천 방법.

발명의 설명

기술 분야

[0001] 본 발명은 추천 장치 및 방법에 관한 것으로, 그래프 신경망을 이용한 부호 인지 추천 장치 및 방법에 관한 것이다.

배경 기술

[0002] 추천 장치는 전자 상거래, 광고 및 소셜 미디어 사이트와 같은 다양한 분야에서 고객에게 적합한 추천 솔루션을 제공하는 방법으로 널리 이용되고 있다. 추천 장치에서 잘 알려진 기술 중 하나는 상호 작용 내역을 기반으로 사용자들과 아이템들 사이의 유사도를 계산하여 유사 사용자들을 판별하고, 판별된 유사 사용자들은 아이템에

대한 선호도 또한 유사하다고 가정하여, 유사 사용자가 선호한 아이템을 추천하는 협업 필터링(Collaborative Filtering: CF)이다.

[0003] 한편 최근에는 사용자-아이템 상호 작용에 대한 고차 연결 정보를 저차원의 가상 임베딩 공간 상의 벡터로 모델링하는 네트워크 임베딩(Network Embedding: NE) 기법을 이용하는 추천 장치가 활발하게 연구되고 있다. 네트워크 임베딩 기법에서는 사용자와 아이템과 같은 객체에 해당하는 노드와 노드들 사이에 연결되어, 연결된 노드들 사이의 관계를 나타내는 엣지로 구성되는 그래프 구조를 기반으로 노드들을 임베딩 공간에 벡터화하는 인공 신경망인 그래프 신경망(Graph Neural Network: 이하 GNN)이 대표적이다.

[0004] GNN은 노드와 엣지로 구성된 그래프를 인가받고, 노드 정보와 함께 노드들 사이를 잇는 엣지를 분석함으로써 각 노드들을 벡터화하여 임베딩 공간상에 배치한다. 그리고 그래프 구조에서 노드들 사이에 연결된 엣지를 통해 이웃 노드와 메시지를 교환함으로써, 각 노드의 상태, 즉 노드에 대한 정보를 업데이트하여 임베딩 공간 상에서 벡터화되어 배치된 노드들의 위치를 변경한다. GNN은 기본적으로 대상 노드와 이웃 노드가 서로 유사하다는 가정하에서 엣지로 연결된 이웃 노드의 정보를 메시지로 전달하여 집계함으로써, 대상 노드의 정보가 업데이트되도록 한다. GNN은 다수의 객체 사이의 관계를 표현함에 있어 매우 우수한 성능을 나타내는 인공 신경망으로, 현재도 각종 추천 장치에서 적용되고 있다.

[0005] 그러나 기존의 GNN을 포함한 다양한 네트워크 임베딩 기법은 기본적으로 아이템에 대한 사용자의 선호도, 즉 노드들 사이의 긍정적인 상호 작용만을 고려하여 노드를 벡터화한다. 따라서 유사 사용자는 유사 아이템에 대해 공통으로 호감을 갖는 사용자로 선택된다. 이에 사용자의 비선호도 또한 선호도와 마찬가지로 아이템과의 상호 작용에 대해 많은 정보를 제공할 수 있으나, 이전 네트워크 임베딩 기법에서는 비선호도가 고려되도록 구성되지 않아 해당 정보를 활용할 수 없었다는 한계가 있다.

[0006] 일 예로 각종 제품이나 영화 또는 음악과 같은 각종 미디어 콘텐츠 등의 아이템과 사용자와의 관계 정보는 통상 1 ~ 5점 범위의 평가 점수 형태로 나타나게 된다. 그리고 이러한 평가 점수에서 4점 또는 5점과 같은 높은 점수는 해당 아이템에 대한 선호도를 나타내는 반면, 1점 또는 2점의 낮은 점수는 비선호도를 나타낸다. 그럼에도 평가 점수 자체가 모두 양의 값을 가짐에 따라 기존의 임베딩 장치에서는 평가 점수가 모두 긍정적 평가라는 기반하여 높은 평가 점수는 높은 선호도로 고려하고, 낮은 평가 점수는 낮은 선호도로만 고려할 뿐, 낮은 평가 점수가 사용자의 비선호도라는 부정적 평가를 고려하지 않기 때문에 많은 정보를 소실하게 된다. 특히 부정적 평가는 사용자가 아이템에 대한 평가를 수행하지 않은 무관계 또는 무관심과 명확히 다른 정보임에도 기존에는 부정적 평가와 무관계가 구분되어 반영되지 않는다는 한계가 있다.

선행기술문헌

특허문헌

[0007] (특허문헌 0001) 한국 등록 특허 제10-2284436호 (2021.07.27 등록)

발명의 내용

해결하려는 과제

[0008] 본 발명의 목적은 사용자의 아이템에 대한 긍정적 평가와 부정적 평가에 따른 선호도와 비선호도를 고려하여 사용자에게 적합한 아이템을 정확하게 추천할 수 있는 추천 장치 및 방법을 제공하는데 있다.

과제의 해결 수단

[0009] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 따른 추천 장치는 다수의 사용자 각각에 대응하는 다수의 사용자 노드와 다수의 아이템 각각에 대응하는 다수의 아이템 노드 및 다수의 사용자의 각 아이템에 대한 평가 점수가 가중치로 가중되어 사용자 노드와 아이템 노드를 잇는 다수의 엣지로 구성된 이분 그래프에서 상기 가중치에 따라 상기 다수의 엣지를 포지티브 엣지와 네거티브 엣지로 구분하고 분할하여, 상기 포지티브 엣지를 갖는 포지티브 그래프와 상기 네거티브 엣지를 갖는 네거티브 그래프를 생성하는 그래프 생성부; 인공 신경망으로 구현되어, 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 포지티브 그래프와 상기 네거티브 그래프 각각을 벡터화하여 포지티브 임베딩 벡터와 네거티브 임베딩 벡터를 획득하고, 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터가 결합된 결합 임베딩 벡터를 획득함으로써, 가상의 공통 임베딩 공간에서 상기 다수의

사용자 노드와 상기 다수의 아이템 노드의 위치를 결정하는 임베딩부; 및 상기 임베딩 공간에서 상기 다수의 사용자 노드 각각에 대한 상기 다수의 아이템 노드 각각의 거리를 기반으로 각 사용자에게 아이템을 추천하는 추천부를 포함한다.

- [0010] 상기 임베딩부는 상기 다수의 사용자의 상기 다수의 아이템에 대한 선호도를 나타내는 상기 포지티브 그래프를 인가받아 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 각각을 벡터화하여 상기 포지티브 임베딩 벡터를 획득하는 포지티브 임베딩부; 상기 다수의 사용자의 상기 다수의 아이템에 대한 비선호도를 나타내는 상기 네거티브 그래프를 인가받아 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 각각을 벡터화하여 네거티브 임베딩 벡터를 획득하는 네거티브 임베딩부; 및 미리 학습된 방식에 따라 신경망 연산을 수행하여 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터 각각에 대응하는 포지티브 중요도와 네거티브 중요도를 추정하고, 상기 포지티브 중요도와 상기 네거티브 중요도를 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터에 가중합하여 상기 결합 임베딩 벡터를 획득하는 통합 강조 임베딩부를 포함할 수 있다.
- [0011] 상기 포지티브 임베딩부는 GNN(Graph Neural Network)로 구현되고, 상기 네거티브 임베딩부는 MLP(Multi-layer Perceptron)로 구현될 수 있다.
- [0012] 상기 그래프 생성부는 상기 이분 그래프에서 다수의 엣지 각각의 가중치가 기지정된 기준 가중치 이상인지 판별하여, 기준 가중치 이상인 엣지를 상기 포지티브 엣지로 설정하고, 가중치가 상기 기준 가중치 미만인 엣지를 상기 네거티브 엣지로 설정하여 부호화된 엣지를 포함하는 부호 그래프를 획득하는 부호 그래프 획득부; 및 상기 부호 그래프를 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 및 상기 포지티브 엣지로 구성되는 상기 포지티브 그래프와 상기 다수의 사용자 노드와 상기 다수의 아이템 노드 및 상기 네거티브 엣지로 구성되는 상기 네거티브 그래프로 분할하는 분할 그래프 획득부를 포함할 수 있다.
- [0013] 상기 그래프 생성부는 상기 다수의 사용자가 다수의 아이템에 대해 평가한 평가 점수가 포함된 평가 데이터를 인가받고, 상기 평가 데이터로부터 상기 다수의 사용자 각각에 대응하는 상기 다수의 사용자 노드와 상기 다수의 아이템에 대응하는 상기 다수의 아이템 노드 및 각 사용자의 각 아이템에 대한 평가 여부에 따라 사용자 노드와 아이템 노드를 잇는 다수의 엣지를 생성하고, 평가 점수를 생성된 엣지의 가중치로 설정하여 상기 이분 그래프를 획득하는 이분 그래프 획득부를 더 포함할 수 있다.
- [0014] 상기 추천 장치는 학습 시에 구비되어 인공 신경망으로 구현되는 상기 임베딩부를 학습시키는 부호 인지 학습부를 더 포함하고, 상기 부호 인지 학습부는 상기 이분 그래프의 엣지를 상기 포지티브 엣지와 상기 네거티브 엣지로 부호화한 부호화 그래프에서 다수의 사용자 노드 각각에 엣지로 연결된 아이템 노드인 연관 아이템 노드와 엣지로 연결되지 않은 아이템 노드인 무연관 아이템 노드로 구성되는 다수의 트리플렛 샘플을 획득하여 다수의 배치를 획득하고, 획득된 트리플렛 샘플에서 상기 연관 아이템 노드의 부호에 따른 사용자 노드와 연관 아이템 노드 및 무연관 아이템 노드 각각에 대한 상기 공통 임베딩 공간에서의 관계로 계산되는 부호 인지 BPR 손실과 정규화에 따른 정규화 손실의 합으로 부호 인지 손실을 계산하여 역전파할 수 있다.
- [0015] 상기 목적을 달성하기 위한 본 발명의 다른 실시예에 따른 추천 방법은 다수의 사용자 각각에 대응하는 다수의 사용자 노드와 다수의 아이템 각각에 대응하는 다수의 아이템 노드 및 다수의 사용자의 각 아이템에 대한 평가 점수가 가중치로 가중되어 사용자 노드와 아이템 노드를 잇는 다수의 엣지로 구성된 이분 그래프에서 상기 가중치에 따라 상기 다수의 엣지를 포지티브 엣지와 네거티브 엣지로 구분하고 분할하여, 상기 포지티브 엣지를 갖는 포지티브 그래프와 상기 네거티브 엣지를 갖는 네거티브 그래프로 분할된 그래프를 생성하는 단계; 미리 학습된 인공 신경망을 이용하여 상기 포지티브 그래프와 상기 네거티브 그래프 각각에 대해 신경망 연산을 수행하여 벡터화된 포지티브 임베딩 벡터와 네거티브 임베딩 벡터를 획득하고, 상기 포지티브 임베딩 벡터와 상기 네거티브 임베딩 벡터가 결합된 결합 임베딩 벡터를 획득함으로써, 가상의 공통 임베딩 공간에서 상기 다수의 사용자 노드와 상기 다수의 아이템 노드의 위치를 결정하여 임베딩하는 단계; 및 상기 임베딩 공간에서 상기 다수의 사용자 노드 각각에 대한 상기 다수의 아이템 노드 각각의 거리를 기반으로 각 사용자에게 아이템을 추천하는 단계를 포함한다.

발명의 효과

- [0016] 따라서, 본 발명의 실시예에 따른 추천 장치 및 방법은 평가 데이터를 이용하여 획득되는 사용자와 아이템 사이의 관계를 나타내는 이분 그래프로부터 사용자의 각 아이템에 대한 선호도와 비선호도를 나타내는 포지티브 그래프와 네거티브 그래프를 구분하여 추출하고, 추출된 포지티브 그래프와 네거티브 그래프 각각을 기반으로 사

용자와 아이템에 대응하는 다수의 노드들을 벡터화하여 공통의 가상 임베딩 공간에 임베딩함으로써 유사 사용자의 아이템들에 대한 선호도뿐만 아니라 비선호도를 고려하여, 사용자가 확실히 선호할 수 있는 아이템을 정확하게 추천할 수 있도록 한다.

도면의 간단한 설명

- [0017] 도 1은 본 발명의 일 실시예에 따른 그래프 신경망을 이용한 부호 인지 추천 장치의 개략적 구성을 나타낸다.
- 도 2는 도 1의 부호 인지 추천 장치의 각 구성에 따른 개략적 동작을 설명하기 위한 도면이다.
- 도 3은 도 1의 그래프 생성부의 상세 동작을 설명하기 위한 도면이다.
- 도 4는 도 1의 포지티브 임베딩부가 포지티브 임베딩 벡터를 획득하는 동작을 상세하게 설명하기 위한 도면이다.
- 도 5는 도 1의 부호 인지 학습부의 상세 동작을 설명하기 위한 도면이다.
- 도 6은 본 발명의 일 실시예에 따른 그래프 신경망을 이용한 부호 인지 추천 방법을 나타낸다.

발명을 실시하기 위한 구체적인 내용

- [0018] 본 발명과 본 발명의 동작상의 이점 및 본 발명의 실시에 의하여 달성되는 목적을 충분히 이해하기 위해서는 본 발명의 바람직한 실시예를 예시하는 첨부 도면 및 첨부 도면에 기재된 내용을 참조하여야만 한다.
- [0019] 이하, 첨부한 도면을 참조하여 본 발명의 바람직한 실시예를 설명함으로써, 본 발명을 상세히 설명한다. 그러나, 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.
- [0020] 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.
- [0021] 도 1은 본 발명의 일 실시예에 따른 그래프 신경망을 이용한 부호 인지 추천 장치의 개략적 구성을 나타내고, 도 2는 도 1의 부호 인지 추천 장치의 각 구성에 따른 개략적 동작을 설명하기 위한 도면이며, 도 3은 도 1의 그래프 생성부의 상세 동작을 설명하기 위한 도면이다.
- [0022] 도 1을 참조하면, 본 실시예에 따른 부호 인지 추천 장치는 데이터 획득부(100), 그래프 생성부(200), 임베딩부(300) 및 추천부(400)를 포함할 수 있다.
- [0023] 데이터 획득부(100)는 다수의 사용자에게 대한 사용자 정보와 다수의 아이템에 대한 아이템 정보 및 다수의 사용자 각각이 다수의 아이템 각각에 대해 평가한 평가 정보를 포함할 수 있다. 여기서 평가 정보는 각 사용자가 각 아이템에 대해 부여한 평가 점수로 구성될 수 있다. 본 실시예에서는 이해의 편의를 위하여 평가 점수는 기 지정된 범위(여기서는 일 예로 1 ~ 5점)의 자연수로 부여될 수 있는 것으로 가정한다.
- [0024] 그래프 생성부(200)는 데이터 획득부(100)에서 획득된 평가 데이터를 기반으로 다수의 사용자와 다수의 아이템 사이의 관계를 나타내는 관계 그래프를 생성한다. 특히 본 실시예에서 그래프 생성부(200)는 도 2 및 도 3의 (c)와 (d)에 도시된 바와 같이, 다수의 사용자와 다수의 아이템 사이의 긍정적인 관계를 나타내는 선호도를 표현하는 포지티브 그래프(G^p)와 부정적인 관계를 나타내는 비선호도를 표현하는 네거티브 그래프(G^n)를 생성한다.
- [0025] 구체적으로 그래프 생성부(200)는 이분 그래프 획득부(210), 부호 그래프 획득부(220) 및 분할 그래프 획득부(230)를 포함할 수 있다.
- [0026] 이분 그래프 획득부(210)는 평가 데이터에서 M명의 사용자 각각을 사용자 노드(u)로 포함하는 사용자 노드 그룹($U = \{u_1 \sim u_M\}$)과 N개의 아이템 각각을 아이템 노드(v)로 포함하는 아이템 노드 그룹($V = \{v_1 \sim v_N\}$) 및 각 사용자 노드(u)와 각 아이템 노드(v) 사이를 이어 사용자 노드(u)와 아이템 노드(v) 간의 관계를 나타내는 다수의 엣지로 포함하는 엣지 그룹(E)으로 구성되는 이분 그래프($G = (U, V, E)$)를 생성한다. 여기서 다수의 엣지 각각은 각 사용자가 각 아이템에 대해 평가한 평가 점수를 가중치(w_{uv})로 갖는다.

- [0027] 이분 그래프($G = (U, V, E)$)에서 다수의 엣지는 사용자 노드(u) 사이를 잇거나 아이템 노드(v) 사이를 잇도록 구성될 수 없다, 그리고 특정 사용자가 특정 아이템을 평가하지 않은 경우에는 가중치(w_{uv})가 0으로 설정되어, 해당 사용자 노드(u)와 해당 아이템 노드(v)를 잇는 엣지는 생략될 수 있다.
- [0028] 이분 그래프 획득부(210)는 도 2 및 도 3의 (a)에 도시된 바와 같이, 다수의 사용자 노드($u_1 \sim u_3$)와 다수의 아이템 노드($v_1 \sim v_5$)를 다수의 엣지를 통해 잇는 형태로 이분 그래프($G = (U, V, E)$)를 획득할 수 있으며, 각 엣지는 평가 점수에 따른 가중치(w_{uv})를 갖는다. 여기서는 평가 점수가 1 ~ 5점 범위에서 자연수로만 설정될 수 있는 것으로 가정하였으므로, 도 2 및 도 3의 (a)에서도 각 엣지에 대한 가중치(w_{uv})가 1 ~ 5 범위의 자연수로 부여되었음을 알 수 있다.
- [0029] 부호 그래프 획득부(220)는 이분 그래프 획득부(210)에서 생성된 이분 그래프(G)에서 다수의 엣지(w_{uv}) 각각의 가중치(w_{uv})가 기지정된 기준 가중치(w_0)보다 큰지 또는 작은지 판별하여, 다수의 엣지 각각을 부호화한다. 여기서 기준 가중치(w_0)는 사용자의 아이템에 대한 선호 또는 비선호를 구분하기 위해 설정된 평가 점수의 기준값으로서, 여기서는 일 예로 기준 가중치(w_0)가 평가 점수 범위의 중간값($w_0 = 3.5$)으로 설정되는 것으로 가정한다. 그러나 기준 가중치(w_0)는 사용자의 아이템에 대한 평가 방식과 평가 점수 부여 방식에 따라 다양하게 설정될 수 있다. 즉 기준 가중치(w_0)는 다수의 사용자의 다수의 아이템에 대한 평가 점수의 평균값이나 다른 기지정된 통계값 등으로 설정될 수도 있다.
- [0030] 부호 그래프 획득부(220)는 이분 그래프(G)에서 엣지 그룹(E)의 다수의 엣지 각각에 부여된 가중치(w_{uv})에서 기준 가중치(w_0)를 차감하여 획득되는 차감 가중치($w_{uv}^s = w_{uv} - w_0$)를 획득한다. 그리고 차감 가중치(w_{uv}^s)의 부호가 포지티브이면($w_{uv}^s > 0$), 즉 가중치(w_{uv})가 기준 가중치(w_0)보다 크면 해당 엣지에 포지티브 부호(+)를 지정하여 포지티브 엣지로 설정하는 반면, 차감 가중치(w_{uv}^s)의 부호가 네거티브이면($w_{uv}^s < 0$), 즉 가중치(w_{uv})가 기준 가중치(w_0)보다 작으면 해당 엣지에 네거티브 부호(-)를 지정하여 네거티브 엣지로 설정하여 엣지 그룹(E)을 부호화 엣지 그룹(E^s)으로 전환함으로써 도 2 및 도 3의 (b)에 도시된 바와 같은 부호 그래프($G^s = (U, V, E^s)$)를 획득한다. 도 2 및 도 3의 (b)에서 실선으로 표시된 엣지는 포지티브 엣지를 나타내고, 점선으로 표시된 엣지는 네거티브 엣지를 나타낸다.
- [0031] 즉 부호 그래프 획득부(220)는 사용자의 아이템에 대한 선호 수준을 상세하게 나타내는 다양한 가중치(w_{uv})가 부여된 엣지를 포지티브 엣지와 네거티브 엣지로 부호화하여 사용자의 아이템에 대한 선호 또는 비선호만을 나타내도록 단순화한 부호 그래프(G^s)를 획득한다.
- [0032] 여기서는 가중치(w_{uv})가 1 ~ 5 범위의 자연수로 설정되고, 기준 가중치(w_0)는 중간값인 3.5로 설정되는 경우를 가정하였으므로, 가중치(w_{uv})와 기준 가중치(w_0)가 동일한 경우($w_{uv} = w_0$)가 존재할 수 없어 생략되었으나, 가중치(w_{uv})와 기준 가중치(w_0)의 설정 방식에 따라서는 가중치(w_{uv})와 기준 가중치(w_0)가 동일한 경우($w_{uv} = w_0$)도 존재할 수 있다. 이와 같이 가중치(w_{uv})와 기준 가중치(w_0)가 동일한 경우, 즉 차감 가중치(w_{uv}^s)가 0인 경우($w_{uv}^s = 0$)에는 미리 지정된 방식에 따라 포지티브 엣지 또는 네거티브 엣지로 설정할 수 있다.
- [0033] 분할 그래프 획득부(230)는 부호 그래프 획득부(220)에서 획득된 부호 그래프(G^s)를 포지티브 엣지와 네거티브 엣지에 따라 구분하여, 도 2 및 도 3의 (c)에 도시된 바와 같은 포지티브 그래프(G^p)와 (d)에 도시된 바와 같은 네거티브 그래프(G^n)의 2개의 독립 그래프로 분할하여 획득한다. 여기서 포지티브 그래프(G^p)와 네거티브 그래프(G^n) 각각은 도 2 및 도 3의 (c)와 (d)에 도시된 바와 같이, 부호 그래프(G^s)의 다수의 노드들, 즉 M 개의 사용자 노드(u)와 N 개의 아이템 노드(v)가 포함된 사용자 노드 그룹(U)과 아이템 노드 그룹(V)은 그대로 유지하되, 포지티브 엣지로만 구성되는 포지티브 엣지 그룹(E^p) 또는 네거티브 엣지로만 구성되는 네거티브 엣지 그룹(E^n) 중 대응하는 하나의 엣지 그룹만을 포함($G^p = (U, V, E^p)$, $G^n = (U, V, E^n)$)하도록 구성될 수 있다.

- [0034] 이와 같이 분할 그래프 획득부(230)에 의해 부호 그래프(G^s)가 포지티브 그래프(G^p)와 네거티브 그래프(G^n)로 분할되면, 포지티브 그래프(G^p)는 사용자의 아이টে에 대한 선호도만을 반영한 그래프로 나타나는 반면, 네거티브 그래프(G^n)는 사용자의 아이টে에 대한 비선호도만을 반영한 그래프로 나타난다. 따라서 각 사용자의 각 아이টে에 대한 선호도와 비선호도를 별개로 구분하여 명확하게 확인할 수 있게 된다.
- [0035] 따라서 그래프 생성부(200)는 다수의 사용자와 다수의 아이টে 사이의 긍정적인 관계를 나타내는 선호도를 표현하는 포지티브 그래프(G^p)와 부정적인 관계를 나타내는 비선호도를 표현하는 네거티브 그래프(G^n)를 획득한다.
- [0036] 임베딩부(300)는 그래프 생성부(200)에서 생성된 포지티브 그래프(G^p)와 네거티브 그래프(G^n)를 이용하여 사용자 노드 그룹(U)의 M개의 사용자 노드(u)와 아이টে 노드 그룹(V)의 N개의 아이টে 노드(v)를 벡터화하여 공통의 임베딩 공간에 투영한다.
- [0037] 임베딩부(300)는 각각 미리 학습된 인공 신경망으로 구현되는 포지티브 임베딩부(310), 네거티브 임베딩부(320) 및 주의 결합 임베딩부(330)를 포함할 수 있다.
- [0038] 여기서 포지티브 임베딩부(310)는 포지티브 그래프(G^p)를 인가받아 포지티브 그래프(G^p)의 M개의 사용자 노드(u)와 N개의 아이টে 노드(v) 각각을 벡터화하여 포지티브 임베딩 벡터(Z^p)를 획득함으로써, 포지티브 그래프(G^p)를 d 차원의 가상의 포지티브 임베딩 공간에 임베딩한다. 즉 벡터화된 M개의 사용자 노드(u)와 N개의 아이টে 노드(v) 각각을 포지티브 임베딩 공간에 위치시킨다. 여기서 포지티브 임베딩 벡터(Z^p)는 $Z^p \in \mathbb{R}^{(M+N) \times d}$ 의 크기로 획득될 수 있다.
- [0039] 포지티브 임베딩부(310)가 기존의 네트워크 임베딩 기법과 마찬가지로, 사용자의 아이টে에 대한 긍정적 선호도를 나타내는 포지티브 그래프(G^p)의 포지티브 엣지 그룹(E^p)을 기반으로 다수의 노드를 임베딩 공간에 임베딩시킨다. 즉 포지티브 임베딩부(310)는 기존과 동일하게 임베딩 공간 상에서 유사한 사용자들이 서로 인접하게 위치하고, 유사한 아이টে들이 서로 인접하게 위치하도록 할뿐만 아니라, 관계성이 높은 사용자와 아이টে들이 서로 가깝게 위치하도록 배치시킨다. 따라서 포지티브 임베딩부(310)는 기존의 네트워크 임베딩 기법에 이용되는 다양한 인공 신경망이 이용될 수 있다.
- [0040] 여기서는 일 예로 포지티브 임베딩부(310)가 상기한 기존의 네트워크 임베딩 기법에 이용되는 대표적인 인공 신경망인 GNN으로 구현되는 것으로 가정한다. 이에 포지티브 임베딩부(310)가 포지티브 그래프(G^p)로부터 포지티브 임베딩 벡터(Z^p)를 획득하는 동작은 이전까지 학습에 의해 획득된 GNN 모델 파라미터(Θ_1)에 따라 미리 학습된 GNN의 신경망 연산(GNN_{θ_1})으로 수행되므로 수학적 식 1과 같이 표현될 수 있다.

수학적 식 1

$$Z^p = GNN_{\theta_1}(G^p)$$

- [0041]
- [0042] 도 4는 도 1의 포지티브 임베딩부가 포지티브 임베딩 벡터를 획득하는 동작을 상세하게 설명하기 위한 도면이다.
- [0043] 구체적으로 포지티브 임베딩부(310)가 GNN으로 구현되므로, 포지티브 임베딩부(310)는 GNN의 방식에 따라 AGGREGATE와 UPDATE라는 두가지 함수를 사용하여 특정 노드(x)에서 엣지로 연결된 인접 노드(y)에 대해 이전 획득된 잠재적 임베딩 벡터(h_y^{l-1})를 집계하고, 집계된 인접 노드(y)의 잠재적 임베딩 벡터(h_y^{l-1})를 이용하여 노드(x)의 잠재적 임베딩 벡터(h_x^l)를 업데이트하는 과정을 반복하는 메시지 전달 방식으로 포지티브 임베딩 벡터(Z^p)를 획득할 수 있다.
- [0044] 도 4를 참조하면, GNN에서는 1번째 GNN 레이어에서 AGGREGATE 함수($AGGREGATE_x^1$)는 이전 (1-1)번째 GNN 레이어

에서 포지티브 그래프(G^p)의 임의의 노드(x)의 이웃 노드(y)의 잠재적 임베딩 벡터(h_y^1)를 집계하여 집계 정보(m_x^1)를 획득한다. AGGREGAE 함수($AGGREGAE_x^1$)를 이용하여 이웃 노드로부터 집계 정보를 획득하는 동작은 수학적 식 5로 표현될 수 있다.

수학적 식 5

$$\mathbf{m}_x^\ell \leftarrow AGGREGAE_x^\ell(\{\mathbf{h}_y^{\ell-1} | y \in \mathcal{N}_x \cup \{x\}\})$$

여기서 $\mathbf{h}_x^{\ell-1} \in \mathbb{R}^{1 \times d_{GNN}^{\ell-1}}$ 는 (1-1) 번째 GNN 레이어에서 노드(x)에 대한 $d_{GNN}^{\ell-1}$ 차원 임베딩 벡터를 나타내고, \mathcal{N}_x 는 포지티브 그래프(G^p)에서 노드(x)에 엣지로 연결된 인접 노드 집합을 나타내며, $\mathbf{m}_x^\ell \in \mathbb{R}^{1 \times d_{GNN}^{\ell-1}}$ 는 1번째 GNN 레이어에서 노드(x)에 대한 집계 정보를 나타낸다.

수학적 식 5에서 노드(x)는 사용자 노드 그룹(U) 또는 아이템 노드 그룹(V)에 속하므로, AGGREGAE 함수($AGGREGAE_x^1$)는 노드(x)가 사용자 노드 그룹(U)에 속한 사용자 노드(u)인 경우, 아이템 노드 그룹(V)에 속한 다수의 아이템 노드(v) 중 엣지로 연결된 아이템 노드의 정보가 집계된다. 반대로, 노드(x)가 아이템 노드(v)이면, 엣지로 연결된 사용자 노드(u)의 정보가 집계된다.

수학적 식 5의 AGGREGAE 함수($AGGREGAE_x^1$)는 수학적 식 6으로 획득될 수 있다.

수학적 식 6

$$AGGREGAE_x^\ell = \sum_{y \in \mathcal{N}_x \cup \{x\}} \frac{1}{\sqrt{|\mathcal{N}_x| + 1} \sqrt{|\mathcal{N}_y| + 1}} \mathbf{h}_y^{\ell-1}$$

본 실시예에서 포지티브 임베딩부(310)는 단순히 다수의 사용자 노드(u)와 다수의 아이템 노드(v)에서 포지티브 엣지로 연결된 포지티브 그래프(G^p)를 이용하므로, 임의의 잠재적 임베딩 벡터(h_x^0)가 초기값으로 설정될 수 있다.

그리고 UPDATE 함수($UPDATE_x^1$)는 1번째 GNN 레이어에서 노드(x)에 대해 집계된 집계 정보(m_x^1)에 따라 노드(x)에 대한 1번째 잠재적 임베딩 벡터(h_x^1)를 업데이트한다. UPDATE 함수($UPDATE_x^1$)를 이용하여 노드(x)에 대한 잠재적 임베딩 벡터(h_x^1)를 획득하는 동작은 수학적 식 7로 표현될 수 있으며, UPDATE 함수($UPDATE_x^1$)는 수학적 식 8로 획득될 수 있다.

수학적 식 7

$$\mathbf{h}_x^\ell \leftarrow UPDATE_x^\ell(x, \mathbf{m}_x^\ell)$$

수학식 8

$$UPDATE_x^\ell = \mathbf{m}_x^\ell \cdot W_{GNN}^\ell$$

여기서 $W_{GNN}^\ell \in \mathbb{R}^{d_{GNN}^{\ell-1} \times d_{GNN}^\ell}$ 은 GNN에서 학습에 의해 결정되는 가중치 행렬로서, GNN 모델 파라미터(Θ_1)이다.

그리고 다수의 레이어($1, \dots, L_{GNN}$) 중 최종 레이어 획득된 잠재적 임베딩 벡터($\mathbf{h}_x^{L_{GNN}}$)는 과평활화(over-smoothing)되는 경향이 있으므로, 이를 완화하기 위해, 집계 레이어(LAYER-AGG $_x^{L_{GNN}}$)가 더 추가되어 레이어 별로 획득된 잠재적 임베딩 벡터($\mathbf{h}_x^0, \dots, \mathbf{h}_x^{L_{GNN}}$)를 집계함으로써, 노드(x)에 대한 포지티브 임베딩 벡터($\mathbf{z}_x^p \in \mathbb{R}^{1 \times d}$)를 획득한다. 집계 레이어(LAYER-AGG $_x^{L_{GNN}}$)가 각 노드(x)에 대한 포지티브 임베딩 벡터(\mathbf{z}_x^p)를 획득하는 동작은 수학식 9로 표현될 수 있다.

수학식 9

$$\mathbf{z}_x^p \leftarrow \text{LAYER-AGG}_x^{L_{GNN}} \left(\{\mathbf{h}_x^\ell\}_{\ell=0}^{\ell=L_{GNN}} \right)$$

그리고 수학식 9에서 LAYER-AGG $_x^{L_{GNN}}$ 함수는 수학식 10으로 표현될 수 있다.

수학식 10

$$\text{LAYER-AGG}_x^{L_{GNN}} = \mathbf{h}_x^0 \parallel \mathbf{h}_x^1 \parallel \dots \parallel \mathbf{h}_x^{L_{GNN}}$$

수학식 10에서 \parallel 는 결합 연산자(concatenation operator)를 나타낸다.

경우에 따라서 포지티브 임베딩부(310)는 최근 제안된 LightGCN으로 구현되어, 수학식 6, 8 및 10의 AGGREGAE 함수(AGGREGATE $_x^1$)와 UPDATE 함수(UPDATE $_x^1$) 및 LAYER-AGG $_x^{L_{GNN}}$ 함수가 각각 수학식 11 내지 13으로 대체될 수도 있다.

수학식 11

$$\text{AGGREGATE}_x^\ell = \sum_{y \in \mathcal{N}_x} \frac{1}{\sqrt{|\mathcal{N}_x|} \sqrt{|\mathcal{N}_y|}} \mathbf{h}_y^{\ell-1}$$

수학식 12

$$UPDATE_x^\ell = \mathbf{m}_x^\ell$$

수학식 13

$$LAYER-AGG_x^{L_{GNN}} = \frac{1}{L_{GNN} + 1} \sum_{\ell=0}^{L_{GNN}} \mathbf{h}_x^\ell$$

[0063]

[0064]

다만 상기한 바와 같이, 본 실시예의 포지티브 임베딩부(310)는 기존 GNN에 기반하는 다양한 인공 신경망으로 구현될 수 있으며, 적용된 신경망에 따라 서로 다른 연산을 수행하도록 구성될 수도 있다.

[0065]

한편, 네거티브 임베딩부(320)는 네거티브 그래프(G^n)를 인가받아 네거티브 그래프(G^n)의 M개의 사용자 노드(u)와 N개의 아이템 노드(v) 각각을 벡터화하여 네거티브 임베딩 벡터(Z^n)를 획득한다. 네거티브 임베딩부(320)는 벡터화된 M개의 사용자 노드(u)와 N개의 아이템 노드(v) 각각을 획득하여 d 차원의 가상의 네거티브 임베딩 공간에 임베딩한다. 여기서 네거티브 임베딩 벡터(Z^n) 또한 $\mathbf{Z}^n \in \mathbb{R}^{(M+N) \times d}$ 의 크기로 획득될 수 있다.

[0066]

네거티브 임베딩부(320)는 기존의 네트워크 임베딩 기법과 달리, 사용자의 아이템에 대한 부정적 평가인 비선호도를 나타내는 네거티브 그래프(G^n)의 네거티브 엣지 그룹(E^n)을 기반으로 다수의 노드를 임베딩 공간에 임베딩 시키므로, 임베딩 공간 상에서 유사한 사용자들이 서로 인접하게 위치하고, 유사한 아이템들이 서로 인접하게 위치하도록 하는 포지티브 임베딩부(310)와 달리, 관계성이 낮은 사용자와 아이템들이 서로 멀게 위치하도록 배치시켜야 한다. 따라서 네거티브 그래프(G^n)에서는 기존의 네트워크 임베딩 기법에 이용되는 인공 신경망은 이용할 수 없다.

[0067]

이에 본 실시예에서는 일 예로 네거티브 임베딩부(320)는 딥 러닝 기법으로 학습되어 획득된 MLP 모델 파라미터(Θ_2)가 적용된 다층 퍼셉트론(Multi-layer Perceptron: 이하 MLP)으로 구성한다. 네거티브 임베딩부(320)가 네거티브 그래프(G^n)로부터 네거티브 임베딩 벡터(Z^n)를 획득하는 동작은 학습된 MLP의 신경망 연산(MLP_{θ_2})으로 수행되므로 수학식 14와 같이 표현될 수 있다.

수학식 14

$$\mathbf{Z}^n = \text{MLP}_{\theta_2}(\mathbf{G}^n)$$

[0068]

[0069]

여기서 MLP의 각 레이어(MLP_1)는 학습에 의해 획득되는 가중치 행렬($\mathbf{W}_{\text{MLP}}^1$)과 바이어스 벡터($\mathbf{b}_{\text{MLP}}^1$)에 따라 연산을 수행하고, 활성 함수(Activation Function)으로서 ReLU(Rectified Linear Unit)를 적용하여 수학식 15에 따라 각 레이어의 네거티브 임베딩 벡터(\mathbf{Z}_1^n)를 출력할 수 있다.

수학식 15

$$\mathbf{Z}_\ell^n = \text{ReLU}(\mathbf{Z}_{\ell-1}^n \mathbf{W}_{\text{MLP}}^\ell + \mathbf{1}_{\text{MLP}} \mathbf{b}_{\text{MLP}}^\ell)$$

[0070]

[0071]

여기서 $\mathbf{1}_{\text{MLP}}^1$ 은 모든 원소가 1인 $\mathbf{1}_{\text{MLP}} \in \mathbb{R}^{(M+N) \times 1}$ 크기의 벡터이고, \mathbf{Z}_0^n 은 임의의 초기 레이어 네거티브 임베딩 벡터이다.

[0072]

그리고 수학식 16과 같이, 최종 레이어(L_{MLP})에서 출력되는 레이어 네거티브 임베딩 벡터($\mathbf{Z}_{L_{\text{MLP}}}^n$)가 곧 네거티브 임베딩 벡터(\mathbf{Z}^n)로 적용된다.

수학식 16

$$\mathbf{Z}^n = \mathbf{Z}_{L_{MLP}}^n$$

따라서 가중치 행렬 집합($\{W_{MLP}^\ell\}_{\ell=1}^{\ell=L_{MLP}}$)과 바이어스 벡터 집합($\{b_{MLP}^\ell\}_{\ell=1}^{\ell=L_{MLP}}$) 및 초기 레이어 네거티브 임베딩 벡터(Z_0^n)가 MLP 모델 파라미터(Θ_2)에 해당하는 것으로 볼 수 있다.

주의 결합 임베딩부(330)는 포지티브 임베딩 벡터(Z^p)와 네거티브 임베딩 벡터(Z^n)를 인가받고, 미리 학습된 방식에 따라 신경망 연산을 수행하여 획득되는 포지티브 임베딩 벡터(Z^p)와 네거티브 임베딩 벡터(Z^n)에 대응하는 중요도($\alpha^p, \alpha^n: \alpha^p, \alpha^n \in \mathbb{R}^{(M+N) \times 1}$)를 수학식 17과 같이 가중합하여 결합 임베딩 벡터(Z)를 획득함으로써, M개의 사용자 노드와 N개의 아이템 노드를 공통의 임베딩 공간에 임베딩한다. 즉 포지티브 임베딩 공간에 배치된 노드들과 네거티브 임베딩 공간에 배치된 노드들 중 서로 대응하는 노드들을 병합하여 공통 임베딩 공간으로 통합한다.

수학식 17

$$\mathbf{Z} = (\alpha^p \mathbf{1}_{attn}) \odot \mathbf{Z}^p + (\alpha^n \mathbf{1}_{attn}) \odot \mathbf{Z}^n$$

여기서 $\mathbf{1}_{attn}$ 는 모든 원소가 1인 $\mathbf{1}_{attn} \in \mathbb{R}^{1 \times d}$ 크기의 벡터이다.

본 실시예에서는 인공 신경망으로 구성되는 주의 결합 임베딩부(330)가 이전 학습에 의해 설정된 주의 모델 파라미터(Θ_3)를 기반으로 수행되는 주의 추출 신경망 연산(ATTENTION $_{\theta_3}$)을 수행하여 포지티브 중요도(α^p)와 네거티브 중요도(α^n)를 획득하는 것으로 고려하며, 이 동작은 간략하게 수학식 18와 같이 표현할 수 있다.

수학식 18

$$(\alpha^p, \alpha^n) = \text{ATTENTION}_{\theta_3}(\mathbf{Z}^p, \mathbf{Z}^n)$$

노드(x)에 대한 포지티브 임베딩 벡터(z_x^p)와 네거티브 임베딩 벡터(z_x^n) 각각에 대한 주의값(attention values)를 w_x^p, w_x^n 라 하면, 포지티브 주의값(w_x^p)과 네거티브 주의값(w_x^n)은 각각 수학식 19 및 20과 같이 표현될 수 있다.

수학식 19

$$w_x^p = \mathbf{q}^T \tanh(W_{attn} \mathbf{z}_x^p + \mathbf{b})$$

수학식 20

$$w_x^n = \mathbf{q}^T \tanh(W_{\text{attn}} \mathbf{z}_x^n + \mathbf{b})$$

여기서 $\tanh(x)$ 는 $\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)}$ 로 계산되는 쌍곡선 탄젠트 활성화 함수이고, \mathbf{q} , W_{attn} 및 \mathbf{b} 는 각각 학습에 의해 획득되는 주의 결합 임베딩부(330)의 주의 모델 파라미터(Θ_3)로서 주의 벡터, 가중치 행렬 및 바이어스 벡터를 나타낸다.

중요도(α^p , α^n)는 수학식 19 및 20의 포지티브 주의값(w_x^p)과 네거티브 주의값(w_x^n)은 각각에 softmax 함수를 적용하여 수학식 21 및 22와 같이 획득될 수 있다.

수학식 21

$$\alpha_x^p = \frac{\exp(w_x^p)}{\exp(w_x^p) + \exp(w_x^n)}$$

수학식 22

$$\alpha_x^n = \frac{\exp(w_x^n)}{\exp(w_x^p) + \exp(w_x^n)}$$

수학식 21 및 22에 의해 중요도(α^p , α^n)가 계산되면, 수학식 17에 따라 결합 임베딩 벡터(\mathbf{Z})가 획득될 수 있다.

임베딩부(300)는 그래프 생성부(200)에서 획득된 포지티브 그래프(G^p)와 네거티브 그래프(G^n)를 이용하여 사용자의 아이템에 대한 선호도와 함께 비선호도를 모두 고려하여 사용자와 아이템들 사이의 관계 유사도를 나타내는 임베딩 벡터(\mathbf{Z})를 획득할 수 있다.

여기서 결합 임베딩 벡터(\mathbf{Z})로 벡터화된 M 개의 사용자 노드와 N 개의 아이템이 배치된 공통 임베딩 공간에서는 도 2의 (g)에 도시된 바와 같이, 유사한 특성의 사용자들이 밀집되어 배치되고, 유사한 특성의 아이템들이 밀집되어 배치되며, 각 사용자로부터 선호도가 높은 아이템에 대응하는 아이템 노드는 해당 사용자 노드에 인접하여 위치하는 반면, 비선호도가 높은 아이템에 대응하는 아이템 노드는 사용자 노드로부터 멀게 배치된다.

이에 추천부(400)는 공통 임베딩 공간에서 아이템 추천 대상이 되는 사용자에게 대응하는 사용자 노드를 탐색하고, 탐색된 사용자 노드를 기준으로 N 개의 아이템 노드까지의 거리를 계산하여, 가까운 거리에 배치된 아이템 노드로부터 순차적으로 기지정된 개수의 아이템 노드에 해당하는 아이템들을 사용자에게 추천한다.

결과적으로 본 실시예에 따른 추천 장치는 사용자들의 다수의 아이템에 대한 선호도뿐만 아니라 비선호도를 함께 고려하여 추천 대상을 선택하도록 함으로써, 단순히 선호도만을 고려하는 기존의 추천 장치보다 더 정확하게 사용자에게 적합한 아이템을 추천할 수 있다.

다만 본 실시예에 따른 추천 장치를 실제 이용하기 위해서는 인공 신경망으로 구현되는 임베딩부(300)의 포지티브 임베딩부(310), 네거티브 임베딩부(320) 및 주의 결합 임베딩부(330)가 미리 학습되어야 한다. 이에 본 실시예의 추천 장치는 임베딩부(300)를 학습시키기 위한 부호 인지 학습부(500)를 더 포함할 수 있다. 부호 인지 학습부(500)는 학습 과정에서만 구비되며, 학습이 완료된 이후에는 제거될 수 있다.

- [0093] 본 실시예에서 부호 인지 학습부(500)는 기존의 추천 시스템에서도 학습을 위해 이용되는 BPR(Bayesian personalized ranking) 손실을 수정한 부호 인지 BPR 손실을 기반으로 학습이 수행된다.
- [0094] 도 5는 도 1의 부호 인지 학습부의 상세 동작을 설명하기 위한 도면이다.
- [0095] 부호 인지 학습부(500)는 학습을 통해 GNN 모델 파라미터(Θ_1)와 MLP 모델 파라미터(Θ_2) 및 주의 모델 파라미터(Θ_3)로 구성되는 모델 파라미터 집합($\Theta = \{\Theta_1, \Theta_2, \Theta_3\}$)을 획득해야 하며, 이를 위해서는 우선 모델 파라미터 집합(Θ)의 GNN 모델 파라미터(Θ_1)와 MLP 모델 파라미터(Θ_2) 및 주의 모델 파라미터(Θ_3)를 임의로 초기화한다.
- [0096] 그리고 부호 그래프(G^s)에서 트리플렛 샘플(u, i, j)로 구성된 배치(D_s)를 학습 데이터로 이용한다. 트리플렛 샘플(u, i, j)은 BPR 손실을 계산하기 위해 주로 활용되는 샘플로서, 트리플렛 샘플(u, i, j)은 부호 그래프(G^s)에서 사용자 노드($u \in U$)와 차감 가중치(w_{ui}^s)를 갖는 엣지로 연결되는 연관 아이템 노드($i \in V$)와 사용자 노드(u)와 엣지로 연결되지 않는 무연관 아이템 노드($j \in V$)로 구성된다. 즉 사용자 노드(u)에 연결된 엣지의 차감 가중치(w_{ui}^s)의 부호와 무관하게, 엣지를 통해 연결된 연관 아이템 노드(i)를 확인하고, 엣지로 연결되지 않은 무연관 아이템 노드(j)를 판별하여 다수의 트리플렛 샘플(u, i, j)을 획득함으로써, 배치(D_s)를 획득한다.
- [0097] 구체적으로 부호 인지 학습부(500)는 부호 그래프(G^s)에서 사용자 노드(u)와 엣지로 연결된 아이템 노드를 판별하고, 엣지로 연결되지 않은 K개의 무연관 아이템 노드($j_n, n = 1, \dots, K$)를 획득하여 다수의 트리플렛 샘플(u, i, j)을 포함하는 배치(D_s)를 생성한다.
- [0098] 여기서 부호 인지 학습부(500)가 다수의 트리플렛 샘플(u, i, j)을 포함하는 배치(D_s)를 생성하는 것은 엣지의 부호와 무관하게 사용자 노드(u)와 엣지로 연결된 아이템 노드(i)와 연결되지 않은 아이템 노드(j)가 구분될 필요가 있기 때문이다. 본 발명에서는 비록 연관 아이템 노드(i)의 엣지의 부호가 네거티브일지라도, 사용자 노드(u)에 네거티브 엣지로 연결되는 아이템 노드일지라도 엣지로 연결되지 않는 무연관 아이템 노드(j)에 비해서는 임베딩 공간 상에서 사용자 노드(u)에 보다 가깝게 배치되어야 하는 것으로 가정한다. 이는 비록 아이템 노드가 비호감을 나타내는 네거티브 엣지로 연결될지라도 사용자 노드(u)와 분명한 관련성이 있으므로, 사용자와 아이템 사이의 관계를 나타내는 임베딩 공간에서는 무연관 아이템 노드(j)보다 사용자 노드(u)에 가깝게 배치될 필요가 있기 때문이다.
- [0099] 그리고 임베딩부(300)에 의해 배치(D_s)의 트리플렛 샘플(u, i, j)에서 연관 아이템 노드(i)에 대한 사용자 노드(u)의 예측 선호도(\hat{r}_{ui})는 임베딩 공간 상의 사용자 노드(u)에 대한 사용자 임베딩 벡터(z_u)와 연관 아이템 노드(i)에 대한 연관 임베딩 벡터(z_i)의 내적(inner product)으로 수학식 23과 같이 정의될 수 있다.

수학식 23

$$\hat{r}_{ui} \triangleq \mathbf{z}_u \mathbf{z}_i^T$$

- [0100]
- [0101] 이와 동일한 방식으로 무연관 아이템 노드(j)에 대한 사용자 노드(u)의 예측 선호도(\hat{r}_{uj}) 또한 계산할 수 있다.
- [0102] 한편, 본 실시예에서는 부호 인지 BPR 손실을 계산하기 위해, 트리플렛 샘플(u, i, j)의 삼항 관계($>_u$)를 수학식 24와 같이 정의한다.

수학식 24

$$\begin{aligned} & >_u (i, j, w) \\ & \triangleq \{(i, j, w) | \hat{r}_{ui} > \hat{r}_{uj} \text{ if } w > 0 \\ & \text{and } -\hat{r}_{ui} > \hat{r}_{uj} \text{ otherwise}\} \end{aligned}$$

[0103]

[0104] 수학식 24에 따르면, 삼항 관계($>_u$)는 엣지의 가중치(w)가 0보다 크면, 사용자 노드(u)와 연관 아이템 노드(i)와의 연관 예측 선호도(\hat{r}_{ui})가 사용자 노드(u)와 연관 아이템 노드(j)와의 무연관 예측 선호도(\hat{r}_{uj})보다 크고, 엣지의 가중치(w)가 0보다 크지 않으면, 사용자 노드(u)와 연관 아이템 노드(i)와의 네거티브 연관 예측 선호도($-\hat{r}_{ui}$)가 사용자 노드(u)와 연관 아이템 노드(j)와의 무연관 예측 선호도(\hat{r}_{uj})보다 크다는 것을 의미한다.

[0105] 수학식 24와 같이 삼항 관계($>_u$)가 정의되면, 부호 인지 BPR 손실(L_0)을 수학식 25에 따라 계산한다.

수학식 25

$$\mathcal{L}_0 = - \sum_{(u,i,j) \in \mathcal{D}'_S} \log p(>_u (i, j, w_{ui}^s) | \Theta)$$

[0106]

[0107] 여기서 $p()$ 는 삼항 관계($>_u$)에 따른 우도(likelihood)를 획득하기 위한 함수로서 수학식 26으로 설정된다.

수학식 26

$$p(>_u (i, j, w_{ui}^s) | \Theta) \triangleq \sigma(\text{sgn}(w_{ui}^s) \hat{r}_{ui} - \hat{r}_{uj})$$

[0108]

[0109] 여기서 $\text{sgn}()$ 는 부호 함수이고, $\sigma(x) = \frac{1}{1+\exp(-x)}$ 로 계산되는 시그모이드 함수이다.

[0110] 최종적으로 부호 인지 학습부(500)는 부호 인지 손실(L)을 수학식 27에 따라 계산할 수 있다.

수학식 27

$$\mathcal{L} = \mathcal{L}_0 + \lambda_{\text{reg}} \|\Theta\|^2$$

[0111]

[0112] 여기서 $\|\cdot\|^2$ 는 L_2 정규화 함수이고, λ_{reg} 는 정규화 강도를 조절하기 위한 하이퍼파라미터이다.

[0113] 즉 부호 인지 학습부(500)는 부호 인지 BPR 손실(L_0)과 정규화에 따른 정규화 손실($\lambda_{\text{reg}} \|\Theta\|^2$)의 합으로 부호 인지 손실(L)을 계산할 수 있다.

[0114] 이에 부호 인지 학습부(500)는 도 5에 도시된 바와 같이, 임베딩부(300)에서 획득된 결합 임베딩 벡터(Z)의 사용자 노드(z_u)와 아이템 노드(z_v)가 공통 임베딩 공간에 배치되는 위치로부터 수학식 27에 따라 부호 인지 BPR 손실(L_0)을 고려하여 계산된 부호 인지 손실(L)을 임베딩부(300)로 역전파함으로써, 임베딩부(300)의 포지티브

임베딩부(310), 네거티브 임베딩부(320) 및 주의 결합 임베딩부(330)를 학습시킬 수 있다. 즉 초기화된 GNN 모델 파라미터(Θ_1)와 MLP 모델 파라미터(Θ_2) 및 주의 모델 파라미터(Θ_3)를 학습을 통해 반복적으로 업데이트하여 임베딩부(300)가 다수의 사용자의 다수의 아이템에 대한 선호도 및 비선호도에 대한 관계와 무관계에 따라 사용자 노드(z_u)와 아이템 노드(z_v)가 공통 임베딩 공간의 적합한 위치에 배치되도록 한다.

[0115] 도 5를 살펴보면, 임베딩부(300)가 학습되기 이전에는 공통 임베딩 공간에 사용자 노드(z_{u1} , z_{u2} , z_{u3})와 아이템 노드(z_{v1} ~ z_{v5})가 혼재되어 배치되었으나, 학습된 이후에는 사용자 노드(z_{u1} , z_{u2} , z_{u3})와 포지티브 엣지로 연결된 아이템 노드들(z_{v2} , z_{v3} , z_{u5})은 사용자 노드(z_{u1} , z_{u2} , z_{u3})에 인접하여 배치된 반면, 네거티브 엣지로 연결된 아이템 노드들(z_{v2} , z_{v3} , z_{u5})은 사용자 노드(z_{u1} , z_{u2} , z_{u3})에서 이격되어 배치되었음을 알 수 있다. 도 5에서는 도시하지 않았으나, 엣지로 연결되지 않은 아이템 노드가 존재하는 경우, 해당 노드들은 네거티브 엣지로 연결된 아이템 노드들(z_{v2} , z_{v3} , z_{u5})보다 사용자 노드(z_{u1} , z_{u2} , z_{u3})로부터 더욱 이격되어 배치될 수 있다.

[0116] 도 6은 본 발명의 일 실시예에 따른 그래프 신경망을 이용한 부호 인지 추천 방법을 나타낸다.

[0117] 도 1 내지 도 5를 참조하면, 본 실시예에 따른 그래프 신경망을 이용한 부호 인지 추천 방법은 크게 그래프 획득 단계(S10), 임베딩 단계(S20) 및 추천 단계(S30)를 포함할 수 있다. 그래프 획득 단계(S10)는 다수의 사용자의 다수의 아이템 각각에 대한 선호도와 비선호도를 각각 나타내는 포지티브 그래프(G^p)와 네거티브 그래프(G^n)를 획득한다. 그리고 임베딩 단계(S20)에서는 미리 학습된 인공 신경망을 이용하여 포지티브 그래프(G^p)와 네거티브 그래프(G^n)에 대해 신경망 연산을 수행함으로써, 다수의 사용자에게 대응하는 다수의 사용자 노드(u)와 다수의 아이템(v)에 대응하는 다수의 아이템 노드를 가상의 공통 임베딩 공간에 학습된 방식에 따라 배치한다. 이후, 추천 단계(S30)는 공통 임베딩 공간 상에서 각 사용자 노드(u)와 각 아이템 노드(v) 사이의 거리에 따라 인접한 순서로 기지정된 N개의 아이템 노드(v)를 선택하여, 해당 아이템을 사용자에게 추천한다.

[0118] 그래프 획득 단계(S10)에서는 우선 다수의 사용자와 다수의 아이템 사이의 관계가 표현된 이분 그래프(G)를 획득한다(S11). 여기서 이분 그래프(G)는 다수의 사용자 각각에 대응하는 다수의 사용자 노드(u)와 다수의 아이템 각각에 대응하는 다수의 아이템 노드(v) 및 다수의 사용자의 각 아이템에 대한 평가 점수가 가중치(w_{uv})로 가중되어 사용자 노드(u)와 아이템 노드(v)를 잇는 다수의 엣지가 포함된다. 만일 특정 사용자의 특정 아이템에 대한 평가 점수가 없다면, 가중치(w_{uv})가 0으로 설정되어, 해당 사용자 노드(u)와 해당 아이템 노드(v)를 잇는 엣지는 생략될 수 있다.

[0119] 그리고 경우에 따라서는 다수의 사용자가 다수의 아이템에 대한 평가 점수가 기록된 평가 데이터를 획득하여, 이분 그래프(G)를 직접 생성할 수도 있다.

[0120] 이분 그래프(G)가 획득되면, 다수의 엣지(w_{uv}) 각각의 가중치(w_{uv})가 기지정된 기준 가중치(w_0)보다 큰지 또는 작은지 판별하여, 다수의 엣지 각각의 가중치(w_{uv})를 $+(+1)$ 또는 $-(-1)$ 로 부호화하여 포지티브 엣지와 네거티브 엣지를 갖는 부호화 그래프(G^s)를 획득한다(S12). 여기서 기준 가중치(w_0)는 일 예로 평가 점수 범위의 중간값($w_0 = 3.5$)으로 설정될 수 있으나, 다른 통계값으로 설정될 수도 있다.

[0121] 부호화 그래프(G^s)를 다수의 엣지 각각의 부호화된 가중치에 따라 포지티브 엣지만을 갖는 포지티브 그래프(G^p)와 네거티브 엣지만을 갖는 네거티브 그래프(G^n)의 2개의 그래프로 분할한다(S13). 이때 다수의 사용자 노드(u)와 다수의 아이템 노드(v)는 유지된다.

[0122] 그리고 임베딩 단계(S20)에서는 포지티브 그래프(G^p)와 네거티브 그래프(G^n)의 2개의 그래프가 획득되면, 포지티브 그래프(G^p)에 대해 GNN과 같이 그래프를 기반하여 네트워크 임베딩을 수행하도록 학습된 인공 신경망을 이용하여, 포지티브 그래프(G^p)의 다수의 사용자 노드(u)와 다수의 아이템 노드(v)를 포지티브 엣지에 의해 확인되는 선호도 관계에 따라 가상의 포지티브 임베딩 공간에 임베딩하여 포지티브 임베딩 벡터(Z^p)를 획득한다(S21).

[0123] 한편, 네거티브 그래프(G^n)에 대해서도 MLP와 같은 학습된 인공 신경망을 이용하여, 네거티브 그래프(G^n)의 다수의 사용자 노드(u)와 다수의 아이템 노드(v)를 네거티브 엣지에 의해 확인되는 비선호도 관계에 따라 가상의 네

거티브 임베딩 공간에 임베딩하여 네거티브 임베딩 벡터(Z^n)를 획득한다(S22). 여기서는 설명의 편의를 위해 포지티브 임베딩 단계(S21)가 수행된 이후, 네거티브 임베딩 단계(S22)가 수행되는 것으로 도시하였으나, 포지티브 임베딩 단계(S21)와 네거티브 임베딩 단계(S22)는 병렬로 동시에 수행될 수 있다.

[0124] 한편, 포지티브 임베딩 벡터(Z^p)와 네거티브 임베딩 벡터(Z^n)가 획득되면, 학습된 인공 신경망을 이용하여, 포지티브 임베딩 벡터(Z^p)와 네거티브 임베딩 벡터(Z^n) 각각에 대한 중요도(α^p , α^n)를 추정한다(S23). 그리고 추정된 중요도(α^p , α^n)를 포지티브 임베딩 벡터(Z^p)와 네거티브 임베딩 벡터(Z^n)에 각각 가중합하여 결합 임베딩 벡터(Z)를 획득함으로써, 다수의 사용자 노드(u)와 다수의 아이템 노드(v)를 공통 임베딩 공간에 임베딩한다(S24).

[0125] 여기서는 포지티브 임베딩 공간과 네거티브 임베딩 공간 및 공통 임베딩 공간을 별도로 구분하여 설명하였으나, 포지티브 임베딩 공간과 네거티브 임베딩 공간 및 공통 임베딩 공간은 모두 동일한 임베딩 공간일 수 있다.

[0126] 이후 추천 단계에서는 공통 임베딩 공간 상에서 다수의 사용자 노드(u) 각각과 다수의 아이템 노드(v) 사이의 거리를 계산한다(S31). 그리고 다수의 사용자 노드(u) 각각에 대해 인접한 순서로 기지정된 N 개의 아이템 노드(v)를 선출하고, 선출된 N 개의 아이템 노드(v)에 따른 N 개의 아이템을 각 사용자 노드(u)에 대응하는 사용자에게 추천한다(S32).

[0127] 한편, 도시하지 않았으나, 임베딩 단계를 수행하기 위해서는 인공 신경망이 미리 학습되어야 하며, 이를 위해서는 학습 단계가 더 포함될 수 있다. 학습 단계에서는 부호화 그래프(G^s)에서 사용자 노드(u)에 엣지로 연결된 연관 아이템 노드(i)와 연결되지 않은 무연관 아이템 노드(j)로 구성되는 다수의 트리플렛 샘플(u, i, j)을 획득하여 다수의 배치(D_s)를 획득하고, 획득된 트리플렛 샘플(u, i, j)에서도 연관 아이템 노드(i)의 부호에 따라 사용자 노드(u)와 연관 아이템 노드(i) 및 무연관 아이템 노드(j) 각각에 대해 공통 임베딩 공간에서 수학적 24와 같이 계산되는 삼항 관계에 따라 부호 인지 BPR 손실(L_0)을 계산하고, 부호 인지 BPR 손실(L_0)과 정규화에 따른 정규화 손실($\lambda_{reg} \|\theta\|^2$)의 합으로 부호 인지 손실(L)을 계산하여 역전파함으로써, 인공 신경망을 학습시킬 수 있다.

[0128] 본 발명에 따른 방법은 컴퓨터에서 실행시키기 위한 매체에 저장된 컴퓨터 프로그램으로 구현될 수 있다. 여기서 컴퓨터 판독가능 매체는 컴퓨터에 의해 액세스될 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(디지털 비디오 디스크)-ROM, 자기 테이프, 플로피 디스크, 광데이터 저장장치 등을 포함할 수 있다.

[0129] 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.


[0130] 따라서, 본 발명의 진정한 기술적 보호 범위는 첨부된 청구범위의 기술적 사상에 의해 정해져야 할 것이다.

부호의 설명

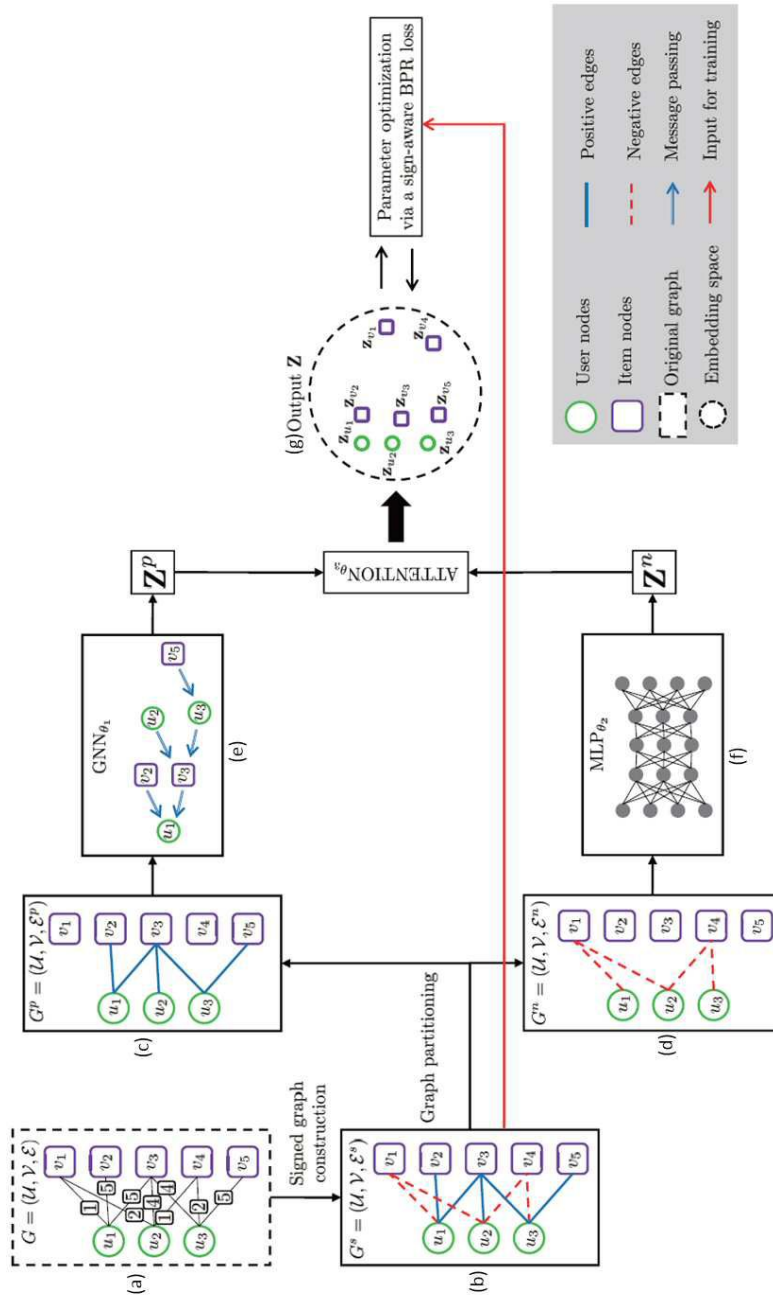
[0131] 100: 데이터 획득부 200: 그래프 생성부
210: 이분 그래프 획득부 220: 부호 그래프 획득부
230: 분할 그래프 획득부 300: 임베딩부
310: 포지티브 임베딩부 320: 네거티브 임베딩부
330: 주의 결합 임베딩부 400: 추천부
500: 부호 인지 학습부

도면


도면1



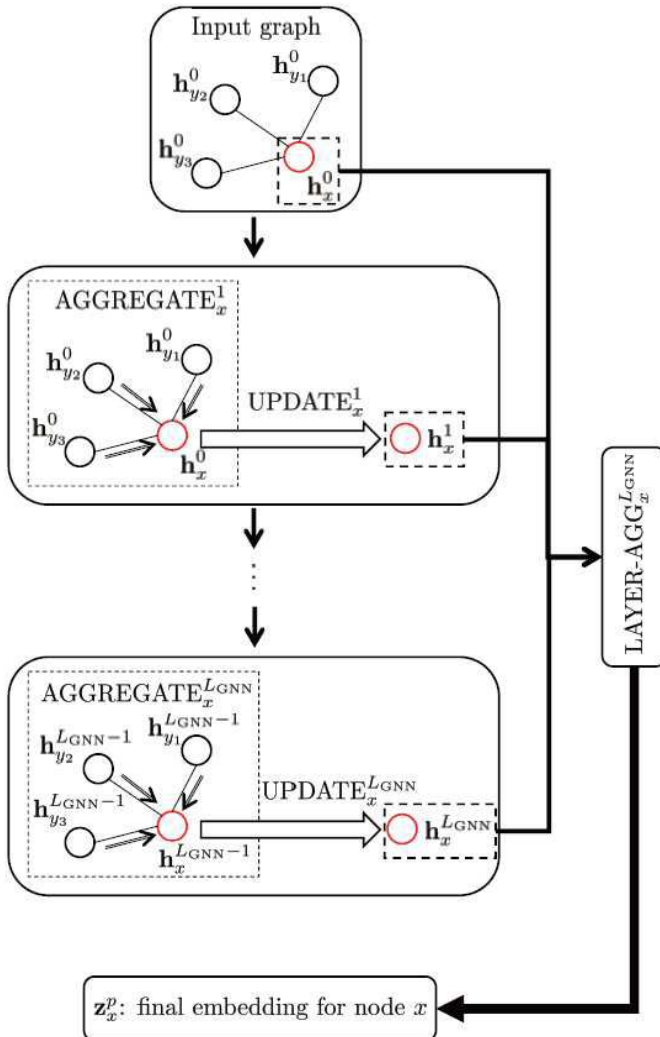
도면2




도면3



도면4



도면5



도면6

