

개인화 추천 시스템에서 FP-Tree를 이용한 연관 군집 방법

Method of Associative Group Using FP-Tree in Personalized Recommendation System

조동주*, 정경용^{oo}, 임기욱^{***}, 이정현^{****}

상지대학교 컴퓨터정보공학부 지능시스템연구실*, 상지대학교 컴퓨터정보공학부**,
선문대학교 컴퓨터정보학부^{oo}, 인하대학교 컴퓨터정보공학부^{****}

Dong-Ju Cho(queen8181@sangji.ac.kr)^o, Kyung-Yong Chung(kyjung@sangji.ac.kr)^{**},
Kee-Wook Rim(ksw0503@hotmail.com)^{***}, Jung-Hyun Lee(jhlee@inha.ac.kr)^{****}

요약

협력적 필터링은 아이템에 대한 선호도를 기반으로 이웃 선정 방법을 사용하므로 내용을 반영하지 못할 뿐만 아니라 희박성 및 확장성 문제를 가지고 있다. 이러한 문제를 개선하기 위하여 아이템 기반 협력적 필터링이 실용화되었으나 아이템의 속성을 반영하지는 못한다. 본 논문에서는 기존의 개인화 추천 시스템의 문제점을 해결하기 위하여 FP-Tree를 이용한 연관 군집 방법을 제안하였다. 제안된 방법으로는 FP-Tree를 이용하여 후보집합의 발생없이 빈발항목을 구성하고 연관규칙을 생성한다. 생성된 연관 규칙의 신뢰도에 따라서 α -cut을 사용하여 효율적인 연관 군집을 한다. 성능평가를 위해 MovieLens 데이터 집합에서 Gibbs Sampling, EM, K-means와 비교 평가하였다.

■ 중심어 : | FP-Tree | 협력적필터링 | 추천시스템 | 연관규칙 | 개인화 |

Abstract

Since collaborative filtering has used the nearest-neighborhood method based on item preference it cannot only reflect exact contents but also has the problem of sparsity and scalability. The item-based collaborative filtering has been practically used improve these problems. However it still does not reflect attributes of the item. In this paper, we propose the method of associative group using the FP-Tree to solve the problem of existing recommendation system. The proposed makes frequent item and creates association rule by using FP-Tree without occurrence of candidate set. We made the efficient item group using α -cut according to the confidence of the association rule. To estimate the performance, the suggested method is compared with Gibbs Sampling, Expectation Maximization, and K-means in the MovieLens dataset.

■ keyword : | FP-Tree | Collaborative Filtering | Recommendation System | Association Rule | Personalization |

* 본 연구는 정보통신부 및 정보통신연구진흥원의 대학 IT연구센터 지원사업의 연구결과로 수행되었습니다.
(ITA-2007-C1090-0701-0020)

1. 서론

오늘날 방대한 데이터베이스 기반과 웹을 기반으로 전자상거래의 발전으로 인해 개인화 추천 시스템의 필요성이 더욱 부각되었다. 이러한 추천 시스템이 사용자를 대신하여 적합한 아이템을 빠른 시간 내에 추천하고 추천 내용 또한 정확하다면 사용자는 만족감을 얻을 수 있다. 일반적인 추천 시스템에서는 협력적 필터링이라고 하는 정보 필터링을 사용한다. 그러나 협력적 필터링은 확장성 문제와 희박성 문제가 남아있다. 대부분의 상업적 추천 시스템은 대용량 아이템 집합을 계산하지만 실제로 사용자가 평가하거나 구매하는 아이템은 수백만 개의 아이템 중 1% 미만에 불과하다. 따라서 같은 아이템을 구매하거나 평가한 사용자의 데이터가 희박하며, 실제 아이템을 추천할 수 없는 경우가 많다. 또한 확장성 문제는 수백만 건의 사용자와 아이템의 데이터 처리를 한다는 점에서 실시간으로 아이템을 추천해야 하는 웹 기반 추천 시스템에게 상당한 부담감으로 작용한다. 이러한 문제점을 해결하기 위하여 본 논문에서는 개인화 추천 시스템에서 FP-Tree (Frequent Pattern Tree)를 이용한 연관 군집 방법을 제안하였다. 제안한 방법은 후보집합을 생성하지 않는 FP-Tree에서 빈발 아이템 간의 연관규칙을 찾고 이를 신뢰도와 α -cut에 적용한 방법이며, 실험을 통해 기존의 추천 시스템과 제안한 방법과 정확도를 비교 평가 하였다. 본 논문의 2장은 개인화 추천 시스템과 Apriori 알고리즘을 기술하고 3장에서는 FP-Tree를 이용한 연관 군집 방법에 대해 기술한다. 그리고 4장과 5장에서는 성능평가 및 결론에 대하여 기술한다.

2. 관련연구

2.1 개인화 추천 시스템

개인화 추천은 사용자에게 자신의 기호에 부합하는 상품이나 정보에 접근하도록 하는 장점이 있다. 개인화 추천 시스템은 학습과 정보 필터링으로 구성되며 학습은 사용자 행위에 따라 사용자의 성향을 학습하는 것을

나타내며 정보 필터링은 사용자에 따른 추천 정보를 나타낸다. 학습은 내용 분석을 기반으로 한 자연어처리 분야와 밀접한 관계를 맺으며 정보 필터링은 필터링 방법에 따라 협력적 필터링, 인구통계학적 필터링, 규칙 기반 필터링으로 나뉜다. 이 같은 필터링 방법은 상호 보완적인 장단점이 있기 때문에 하나의 방법만 사용하기 보다는 이를 병합하여 사용하는 경우가 많다. 또한 협력적 필터링은 사용자 기반의 협력적 필터링과 아이템 기반의 협력적 필터링으로 나뉜다[1]. 사용자 기반의 협력적 필터링은 추천의 대상이 되는 사용자에 대하여 그와 비슷한 취향을 갖는 유사 사용자를 찾고 이들 유사 사용자가 공통적으로 많이 구매하는 아이템 중에서 추천 대상 사용자가 구매하지 않은 아이템을 추천해 주는 방법이다. 아이템 기반의 협력적 필터링은 특정 사용자에게 추천 시에 사용하므로 사용자 기반의 협력적 필터링 보다 효율적이다. 또한 다양한 사용자의 관심분야를 반영하므로 추천 정확도를 높인다. 여기서 아이템 간의 유사도를 계산하기 위한 기존 연구로는 코사인 기반의 유사도, 상관계수 기반의 유사도, 개선된 코사인 기반의 유사도가 있다[2].

2.2 Apriori 알고리즘

Apriori 알고리즘[3]은 이진연관규칙에 대한 빈발 항목집합을 찾아내는데 유용한 알고리즘이다. Apriori 알고리즘 n번째 항목집합이 n+1번째 항목집합을 발견하기 위해 레벨단위로 진행되는 반복 접근법을 사용한다. 첫째로 빈발 1-항목집합을 찾는다. 이 집합을 L1으로 나타낸다. L1은 2-항목집합인 L2을 찾는데 사용되며, 이것은 다시 L3을 찾는데 이용되는 식으로 계속되어 더 이상의 빈발 k-항목집합이 없을 때까지 진행된다. 이러한 Apriori 알고리즘의 특성은 모든 공집합이 아닌 빈발 항목집합의 부분집합은 반드시 빈번하다는 것이다. 항목집합 I가 최소지지도 임계치(minimum support threshold)인 \min_sup 를 만족하지 못하면 I는 빈번하지 않으므로 $P(I) < \min_sup$ 가 된다. 항목 A가 항목집합 I에 추가되면 결과 항목집합은 IUA가 되며 이것 또한 [보다 더 빈번 할 수 없다. 그러므로 IUA는 빈번하지 않으므로 $P(IUA) < \min_sup$ 가 된다[4].

3. FP-Tree를 이용한 연관 군집

기존의 Apriori 알고리즘은 각 노드에서 생성된 후보 항목 집합들 중에서 빈발항목 집합을 찾아내기 위해 매번 계속적으로 대량의 트랜잭션을 스캔해야 하므로 속도가 느릴 뿐 만 아니라 확장성 문제와 정확도 문제가 제기된다. 이러한 문제점을 해결하고자 FP-Tree를 이용한 연관 군집 방법을 제안한다.

3.1 FP-Tree를 이용한 연관규칙

Apriori 알고리즘은 이진연관규칙에 대한 빈발항목집합을 찾아내는데 유용한 알고리즘이지만 이 방법은 대량의 후보집합 생성이 필요하다. 본 논문에서는 후보집합의 발생없이 빈발항목을 생성하는 빈발패턴트리를 압축하여 사용한다. [표 1]은 빈발패턴트리를 만들기 위한 아이템 트랜잭션이다.

표 1. 아이템 트랜잭션과 내림차순 정렬 데이터

| 아이템 트랜잭션 데이터 | | | |
|--------------|------------------|------|------------------|
| TID | List of item_IDs | TID | List of item_IDs |
| T100 | 11, 12, 15 | T600 | 12, 13 |
| T200 | 12, 14 | T700 | 11, 13 |
| T300 | 12, 13 | T800 | 11, 12, 13, 15 |
| T400 | 11, 12, 14 | T900 | 11, 12, 13 |
| T500 | 11, 13 | | |

| 내림차순 정렬 데이터 | | | |
|-------------|------------------|------|------------------|
| TID | List of item_IDs | TID | List of item_IDs |
| T100 | 12, 11, 15 | T600 | 12, 13 |
| T200 | 12, 14 | T700 | 11, 13 |
| T300 | 12, 13 | T800 | 12, 11, 13, 15 |
| T400 | 12, 11, 14 | T900 | 12, 11, 13 |
| T500 | 11, 13 | | |

[표 1]의 아이템 트랜잭션을 스캔하여 최소 지지도를 2라고 가정하고 빈번 아이터 집합의 아이터 지지도를 내림차순으로 정렬한다. 그 다음 "null" 이라는 루트노드를 생성하고 데이터베이스를 스캔한다. 각각의 아이터는 지지도에 따라서 내림차순 정렬의 트랜잭션마다 노드의 리프가 생성된다. 이때 트랜잭션 아이터는 먼저

생성된 노드가 부모 노드가 되고 그 다음 생성된 노드가 자식 노드가 되면서 트리를 구성하게 된다. 하나의 트랜잭션에 리프가 추가되는 경우에는 공통 노드를 하나씩 증가시키고 다음 순서의 트랜잭션에 노드를 생성한 후 링크를 연결해 준다. [그림 1]은 모든 트랜잭션을 스캔한 결과로 얻어진 트리이다. 생성된 FP-Tree는 상향식으로 연관규칙을 생성한다.

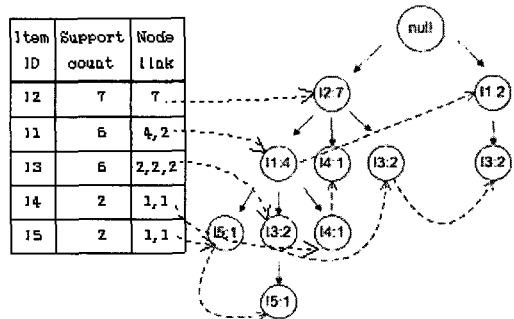


그림 1. 빈발패턴정보를 저장하는 FP-Tree

따라서 데이터베이스에서 빈발패턴을 마이닝하는 문제는 FP-Tree를 마이닝하는 문제로 변환된다.

FP-Tree 마이닝은 초기의 접미패턴에서 시작하여 조건부 패턴베이스를 생성하고 조건부 FP-Tree를 생성한다. 그리고 이 트리에 대해서 재귀적으로 마이닝을 수행한다. 패턴의 증가는 접미부 패턴과 조건부 FP-Tree로부터 생성된 빈발패턴을 결합함으로써 얻어진다. [그림 1]의 I5는 두 개의 노드에서 발견된다. I5를 접미부로 하면 두 개의 접두부 경로는 (I2 I1 I5:1), (I2 I1 I3 I5:1)이며, 접두부 경로들은 조건부 패턴 베이스를 구성한다. I5의 조건부 FP-Tree는 단일 경로 (I2:1, I1:2)가 되는데 I3이 포함되지 못하는 이유는 I3은 지지도가 1로서 최소 지지도보다 작기 때문이다. 이 단일 경로는 빈발패턴의 모든 조합 I2 I5:2, I1 I5:2, I2 I1 I5:2를 생성하게 된다. [표 2]는 위와 같은 방법으로 조건부 패턴집합을 생성하는 FP-Tree를 마이닝한 것이다. 이는 우수한 선택을 제공하는 최소 빈발항목을 접미부로 사용함으로써 기존의 문제점을 해결한다.

표 2. 조건부 패턴집합을 생성하는 FP-Tree 마이닝

| 아이템 | 조건부 패턴집합 | 조건부 빈발패턴트리 | 빈발패턴 아이템 |
|-----|-------------------------------|----------------------|------------------------------|
| I5 | {{(I2 I1:1), (I2 I1 I3:1)}} | [I2:2, I1:2] | I2 I5:2, I1 I5:2, I2 I1 I5:2 |
| I4 | {{(I2 I1:1), (I2:1)}} | [I2:2] | I2 I4:2 |
| I3 | {{(I2 I1:2), (I2:2), (I1:2)}} | [I2:4, I1:2], [I1:2] | I2 I3:4, I1 I3:4, I2 I1 I3:2 |
| I1 | {{(I2:4)}} | [I2:4] | I2 I1:4 |

3.2 α -cut을 이용한 아이템 군집

본 절에서는 연관규칙을 생성한 후 연관 아이템의 군집을 위해 빈발패턴 아이템의 신뢰도를 사용한다. 그리고 연관 아이템의 행렬이 형성되면 α -cut을 적용하여 임계치 이상의 신뢰도를 이용하여 군집하였다. 아이템 간의 신뢰도가 크다는 것은 그만큼 아이템간의 연관성이 높다는 것을 의미하기 때문에 본 논문에서는 임계치보다 높은 신뢰도를 군집하였다. 먼저 데이터베이스로부터 연관규칙을 생성하기 위하여 빈발패턴 아이템을 사용한다. 이는 모든 빈발패턴 아이템에 대해서 빈발패턴 아이템(A)의 모든 공집합이 아닌 부분집합들을 생성한다. A의 모든 공집합이 아닌 부분집합(S)에 대하여 최소 신뢰도 임계치보다 큰 $S \rightarrow (A-S)$ 규칙을 출력한다. [표 3]은 연관 아이템간의 신뢰도 행렬을 나타낸 것이고, [그림 2]는 신뢰도 변화에 따른 연관 아이템에 대한 정확도와 재현율을 나타낸다.

표 3. 연관 아이템간의 신뢰도 행렬

| | Item1 | Item2 | Item3 | Item4 | Item5 | ... | Item10 |
|--------|-------|-------|-------|-------|-------|-----|--------|
| Item1 | 1 | 0.666 | 0.666 | 0.166 | 0.333 | ... | 0.166 |
| Item2 | 0.666 | 1 | 0.571 | 0.285 | 0.285 | ... | 0.382 |
| Item3 | 0.666 | 0.571 | 1 | 0 | 0.166 | ... | 0 |
| Item4 | 0.166 | 0.285 | 0 | 1 | 0 | ... | 0.572 |
| Item5 | 0.333 | 0.285 | 0.166 | 0 | 1 | ... | 0.282 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| Item10 | 0.166 | 0.382 | 0 | 0.571 | 0.282 | 0 | 1 |

[그림 2]는 신뢰도가 클수록 연관 아이템의 정확도는 높아지나 재현율이 낮아짐을 나타낸다. 그러나 0.5 이

상의 신뢰도에서는 재현율이 일정하고 정확도는 높아지는 것을 보인다. 그러므로 적합한 연관 아이템을 찾기 위해서는 신뢰도를 0.5이상으로 지정해야한다.




그림 2. 신뢰도 변화에 따른 정확도와 재현율

[그림 3]은 [표 3]의 연관 아이템간의 신뢰도 행렬에서 α 값을 0.5로 적용한 결과이다. 연관 아이템간의 신뢰도 행렬의 간선을 살펴보면 최종적으로 군집(I1, I2, I3), 군집(I2, I4, I5, I1)로 군집됨을 보여준다.




그림 3. FP-Tree를 이용한 연관 군집의 예

4. 성능평가

성능 평가를 위한 실험 데이터로는 Grouplens 연구 기관에서 제공받은 MovieLens 평가 데이터[5] 집합을 사용하였다. 사용자는 0.0에서부터 1.0까지 0.2간격으로 아이템에 대하여 평가하였으며 또한 사용자가 실제로 영화를 보았는지의 여부를 알 수 있는 가중치 정보가 존재한다. 영화의 장르는 액션, 애니메이션, 외국 예술,

고전, 코미디, 드라마, 가족, 공포, 로맨스, 스릴러의 10 가지로 구분되어 있다.

4.1 실험 방법 및 결과

본 논문에서 제안한 FP-Tree를 이용한 연관 아이템 군집(F-ig)은 MS Visual C++ 6.0으로 구현되었으며 실험 환경은 Pentium IV, 1.9GHz 환경에서 수행되었다. 실험 방법으로는 추천 시스템에서 기존의 피어슨 상관 계수 기반의 협력적 필터링 방법(IB-CF)과 제안한 FP-Tree를 이용한 연관 아이템 군집(F-ig)방법을 실험을 통해 비교 평가하였다. 성능을 평가하기 위한 실험 목적 데이터는 MovieLens 데이터 집합을 전처리한 후 30,861명의 사용자와 1,612종류의 영화에 대해서 실험을 진행하였다.

4.2 분석 및 성능평가

예측 값과 실제 값의 차이를 표시하는 MAE(Mean Absolute Error)방식[7]과 정확도와 재현율을 합한 단위인 *F-measure*를 사용하여 성능 평가하였다.

(식 1)에서 제시한 MAE는 예측의 정확성을 판단하는데 많이 쓰이는 방법이며, 실제 선호도 값과 예측된 선호도 값과의 오차로 정의되고 MAE는 오차의 절대값 평균을 의미한다. MAE는 (식 1)과 같이 정의한다.

$$|E| = \frac{\sum_{i=0}^N |\epsilon_i|}{N} \quad (\text{식 1})$$

여기서 N 은 총 예측 횟수이고, ϵ_i 는 예측 값과 실제 값의 오차를 나타내며 i 는 각 예측 단계를 나타낸다. (식 1)에 실험 데이터 집합의 사용자 수를 증가시킴으로서 성능평가를 한다. [표 4]는 MAE를 이용하여 피어슨 상관계수 방식의 협력적 필터링과 FP-Tree를 이용한 연관 아이템 군집 방법을 실험하여 사용자 수에 따른 성능평가를 나타낸 것이다.

표 4. 사용자 수에 따른 MAE에 의한 성능평가

| 사용자 수 | MAE | |
|-------|------|-------|
| | F-ig | IB-CF |
| 1 | 1.16 | 1.16 |
| 180 | 1.08 | 1.1 |
| 400 | 1 | 1.05 |
| 956 | 0.91 | 0.99 |
| 1490 | 0.86 | 0.95 |
| 2015 | 0.82 | 0.92 |
| 2566 | 0.8 | 0.9 |
| 3110 | 0.73 | 0.88 |
| 3760 | 0.69 | 0.89 |
| 4010 | 0.68 | 0.89 |
| 4380 | 0.66 | 0.91 |
| 5048 | 0.63 | 0.92 |
| 5870 | 0.63 | 0.94 |

아이템에 대해서 평가한 사용자가 적을 경우 전반적으로 연관관계가 높게 나타난다. 이는 가중치의 변별력이 없기 때문이다. 이러한 경우 아이템이 속한 군집의 크기는 매우 큰 반면 아이템이 속한 군집의 수는 매우 적어지게 된다. 또한 많은 사용자가 평가한 아이템에 대해서는 많은 군집에 속하게 되기 때문에 상대적으로 정확도가 낮아지는 경향이 있다.

[그림 4]는 F-ig와 IB-CF에서 사용자의 수에 따른 MAE의 성능평가이다. 초기 평가한 사용자의 수가 1일 때는 군집이 형성되지 않는 시점이라 MAE는 같은 값을 가진다. 그러나 사용자의 수가 늘어나면서 본 논문에서 제안한 방법이 더 좋은 성능을 보임을 알 수 있다. 아이템이 군집 속에 들어가는 수를 제한하고 그 수보다 적을 경우 제안한 방법을 사용하면 정확도 면에서 좋은 성능이 나타난다.




그림 4. F-ig와 IB-CF에서 사용자 수에 따른 MAE




그림 5. 사용자수의 변화에 따른 F-measure 평가

[그림 5]는 EM(Expectation Maximization)[6], Gibbs Sampling[10], K-means[8][9]를 이용하여 사용자 수의 증가에 따른 *F-measure*의 성능변화를 나타낸 것이다. 여기서 정확도와 재현율을 합한 단위인 *F-measure* 측정식은 (식 2)와 같이 나타낸다. *P*는 정확도, *R*은 재현율을 의미하며 *F-measure*의 값이 클수록 분류가 우수함을 의미한다[11].

$$F\text{-Measure} = \frac{2 \times P \times R}{P + R} \quad (\text{식 2})$$

K-means는 군집은 빠르나 정확도가 낮은 단점이 있으며 EM은 사용자를 군집하기 위한 편리한 방법이나 같은 군집에 속한 사용자가 검색한 아이템은 같은 클래스에 있어야 한다는 제한을 갖는다. 또한 Gibbs

Sampling은 정확도는 높으나 복잡하기 때문에 속도가 느리다는 단점을 갖고 있다. 네 가지 방법에서 사용자의 수가 증가함에 따라 *F-measure*에 의한 성능이 점차 향상됨을 보인다. 특히, F-ig는 Gibbs Sampling보다 10.5%, EM보다는 19.9%, K-means보다 32.1%의 높은 성능을 나타냈으며 Gibbs Sampling과 EM, K-means는 사용자 수가 적은 경우에 전체적으로 낮은 성능을 보인다.

5. 결론

본 논문에서 제안한 개인화 추천 시스템에서 FP-Tree를 이용한 연관 군집 방법은 아이템간의 연관 규칙을 생성하고 생성된 연관 아이템간의 신뢰도를 α -cut에 적용하여 연관 군집을 하였다. FP-Tree는 빈발 항목 집합으로부터 최소 지지도와 최소 신뢰도를 만족 하면서 강한 연관규칙을 생성한다. 이러한 연관규칙 기반에 신뢰도와 α -cut을 적용하여 정확도를 향상시키고 추천 시스템의 확장성 문제와 희박성 문제를 해결하였으며 최소 빈발항목을 접미부로 사용함으로써 속도와 탐색비용을 감소시킨다. 연관 아이템의 신뢰도의 가중치를 맵핑하여 α -cut을 적용한다면 실험의 일부에서 나타난 오류를 줄일 수 있으며 정확도 측면에서도 더욱 향상된 추천 시스템을 구현할 수 있다. FP-Tree가 후보집합을 생성하지 않아 Apriori 알고리즘보다 우수하지만 이는 수많은 조건부 FP-Tree를 생성 소멸시킨다. 조건부 FP-Tree를 연속적으로 만들고 제거하기란 어려운 일이며 반복된 작업을 되풀이하여 연산 시간이 늘어나는 단점은 향후 연구이다.

참고 문헌

[1] K. Y. Jung and J. H. Lee, "User Preference Mining through Hybrid Collaborative Filtering and Content-based Filtering in Recommendation System," IEICE Transaction on Information and Systems, Vol.E87-D, No.12, pp.2781-2790, 2004.

[2] B. Sarwar, G. Karypis, J. Konstan, and J. Reidl, "Item-based Collaborative Filtering Recommendation Algorithms," Proc. of the 10th Int. Conf. on WWW. pp.285-295, 2001.

[3] R. Agrawal and R. Srikant, "Mining Sequential Patterns," Proc. of the Int. Conf. on Data Engineering, Taipei, Taiwan, 1995.

[4] Jiwei Han and Micheline Kamber, *Data Mining Concepts and Techniques*, 자유아카데미, 2004.

[5] <http://www.cs.umn.edu/research/GroupLens/> GroupLens Research Project

[6] D. Frank, "The Expectation Maximization Algorithm," Technical Report(GIT-GVU-02-20), Georgia Institute of Technology, 2002.

[7] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, "Evaluating Collaborative Filtering Recommender Systems," ACM Transactions on Information Systems. Vol.22, No.1, pp.5-53, 2004.

[8] C. Ding and X. He, "K-Means Clustering via Principal Component Analysis," Proc. of the Int. Conf. on Machine Learning, pp.225-232, 2004.

[9] M. O. Connor and J. Herlocker, "Clustering Items for Collaborative Filtering," Proc. of the ACM SIGIR Workshop on Recommender Systems, Berkeley, CA, 1999.

[10] G. Casella and E. I. George, "Explaining the Gibbs Sampler," The American Statistician, pp.167-174, 1992.

[11] 한경수, 조동주, 정경용, "개인화 추천시스템에서 속성 정보를 이용한 연관 사용자 군집 방법", 한국정보과학회, 추계학술발표논문집(B), Vol.33, No.2, pp.169-173, 2006.

저 자 소 개

조 동 주(Dong-Ju Cho)

준회원



- 2004년 2월 : 상지대학교 행정학과(행정학사)
- 2006년 3월 ~ 현재 : 상지대학교 컴퓨터정보공학과 석사과정

<관심분야> : 데이터마이닝, 인공지능, 유비쿼터스

정 경 용(Kyung-Yong Chung)

정회원



- 2000년 2월 : 인하대학교 전자계산공학과(공학사)
- 2002년 2월 : 인하대학교 컴퓨터정보공학과(공학석사)
- 2005년 8월 : 인하대학교 컴퓨터정보공학과(공학박사)

- 2005년 8월 ~ 2006년 2월 : 한세대학교 IT학부 교수
- 2006년 3월 ~ 현재 : 상지대학교 컴퓨터정보공학부 교수

<관심분야> : 데이터마이닝, 지능시스템, 인공지능

임 기 욱(Kee-Wook Rim)

정회원



- 1977년 : 인하대학교 전자공학과(공학사)
- 1987년 : 한양대학교 전자계산학(공학석사)
- 1994년 8월 : 인하대학교 전자계산학(공학박사)

- 1977년 ~ 1983년 : 한국전자기술연구소 선임연구원
- 1983년 ~ 1988년 : 한국전자통신연구소 시스템소프트웨어 연구실장
- 1989년 ~ 1996년 : 한국전자통신연구원 시스템연구부장, 주전산기(타이컴)Ⅲ,Ⅳ 개발사업 책임자

- 1997년 ~ 1999년 : 정보통신연구진흥원 정보기술전문위원
 - 2000년 ~ 현재 : 선문대학교 컴퓨터정보학부 교수
- <관심분야> : 실시간데이터베이스시스템, 운영체제, 시스템구조

이 정 현(Jung-Hyun Lee)

정회원



- 1977년 : 인하대학교 전자공학과 (공학사)
- 1980년 : 인하대학교 대학원 전자공학과(공학석사)
- 1988년 : 인하대학교 대학원 전자공학과(공학박사)

- 1979년 ~ 1981년 : 한국전자기술연구소 시스템 연구원
- 1984년 ~ 1989년 : 경기대학교 전자계산학과 교수
- 1989년 ~ 현재 : 인하대학교 컴퓨터공학부 교수

<관심분야> : 자연어처리, HCI, 정보검색, 컴퓨터구조