

<http://dx.doi.org/10.7236/JIWIT.2012.12.4.95>

JIWIT 2012-4-12

PCA와 NMF를 이용한 대화식 드라마의 스토리 경로 추천 시스템 구현

An Implementation of Story Path Recommendation System of Interactive Drama Using PCA and NMF

이연창*, 장재희*, 김명관**

Yeon-Chang Lee, Jae-Hee Jang, Myung-Gwan Kim

요약 대화식 드라마는 사용자의 자유로운 선택과 참여가 요구되는 상호작용성을 가진 이야기를 말한다. 본 논문에서는 이러한 대화식 드라마의 특성을 이용하여 훈련 데이터를 만들어 사용자의 선호도를 파악한다. 그 후 파악된 선호도 특성에 맞게 새로운 사용자들에게 스토리의 경로를 추천하는 시스템 구현 과정을 기술한다. 선호도 특성을 추출하기 위하여 Principal Component Analysis(이하 PCA)와 Non-negative Matrix Factorization(이하 NMF)를 사용하였다. PCA를 이용하여 추천한 결과 성공률은 75%, NMF를 이용하여 추천한 결과 성공률은 62.5%를 나타냈다.

Abstract Interactive drama is a story which requires user's free choice and participation. In this study, we grasp user's preference by making training data that utilize characters of interactive drama. Furthermore, we describe process of implementing systems which recommend new users path of stories that correspond with their preference. We used PCA and NMF to extract characteristic of preference. The success rate of recommending was 75% with PCA, while 62.5% with NMF.

Key Words : Interactive Drama, PCA(Principal Component Analysis), NMF(Non-negative Matrix Factorize), Feature Extraction, Data Mining

1. 서론

아리스토텔레스는 이야기라는 것은 폐쇄된 구조 속에서 가장 극적이며 몰입감 높은 서사 경험을 제공한다고 말했다. 반대로 사용자의 상호작용성은 이러한 폐쇄된 구조를 벗어나 사용자의 자유로운 선택과 참여를 요구한다.^[1] 이러한 특징을 가지는 이야기를 대화식 드라마라고 한다. 즉, 대화식 드라마는 사용자의 자유로운 선택과 참여가 요구되는 상호작용성을 가진 이야기를 말한다. 본

논문에서는 이러한 상호작용성을 가진 대화식 드라마의 스토리 경로를 훈련 데이터에서 추출한 선호도 특성에 맞게 사용자에게 추천하는 시스템의 구현을 목표로 하고 있다.

사용자의 선호도 특성에 맞게 드라마 스토리를 추천하는 연구는 Hong Yu 와 Mark O. Riedl에 의해 진행되어 왔다.^{[2][3]} Hong Yu 와 Mark O. Riedl는 Drama Manager라는 에이전트를 통해서 사용자가 경험하는 특정한 시퀀스의 스토리 전환점(plot point)을 발생시켰다.

*준회원 을지대학교 의료IT마케팅학과 재학생

**정회원, 을지대학교 의료IT마케팅학과 (교신저자)

접수일자 : 2012년 6월 1일, 수정완료 : 2012년 7월 11일

게재확정일자 : 2012년 8월 10일

Received: 1 June 2012 / Revised: 11 July 2012

Accepted: 10 August 2012

**Corresponding Author: binsum@eulji.ac.kr

Dept. of Medical IT & Marketing, Eulji University, Korea

Drama Manager는 사용자에게 개인화된 스토리들을 전달하기 위해 스토리 전환점(plot point)이 이야기 전개에 포함되는지 뿐만 아니라, 사용자가 경험할 수 있는 사건의 최적의 시퀀스도 결정한다.^[2]

본 논문에서는 대화식 드라마의 추천을 위해 두 가지 과정을 거친다. 첫 번째 과정은 선호도 특성을 추출하기 위해 훈련 데이터를 만드는 것이다. 그 후 훈련 데이터를 이용하여 선호도 특성을 추출하는데, 이를 위해 주성분 분석(Principal Component Analysis, 이하 PCA)과 비음수행렬인수분해(Non-negative Matrix Factorization, 이하 NMF)를 이용한다. PCA는 고차원 데이터로부터 데이터의 구조를 밝히거나, 데이터의 차원을 낮추는 데 많이 이용되는 다변량 통계분석 방법^[4]이고, NMF는 대량의 정보를 의미 특징(Semantic Feature)과 의미 변수(Semantic Variable)로 나누어 효율적으로 표현할 수 있는 방법이다.^{[5][6][7]} 이렇게 추출된 선호도 특성을 이용하여 새로운 사용자들에게 스토리의 경로를 추천하는 과정을 기술한다. 최종적으로 PCA와 NMF 중 어떤 특성 추출 방법이 더 정확한 스토리의 경로를 추천하는지 살펴본다.

본 논문의 구성은 다음과 같다. 2장에서는 관련연구를 살펴보고, 3장에서는 시스템의 설계 과정, 그리고 4장에서는 구현한 시스템의 실험 및 결과를 기술한다. 마지막 5장에서는 결론을 맺는다.

II. 관련 연구

1. 대화식 드라마

대화식 드라마(Interactive Drama)라는 개념은 브렌다 로렐 (Brenda Laurel)의 1987년 논문에서 사용자들이 1인칭 주인공 시점으로 참여하는 극적인 이야기를 담은 사고 실험을 통해 처음 언급됐다.^{[8][9]} 이후 자넷 머레이 (Janet Murray)는 사이버 드라마라는 명칭으로, 단순히 인터랙티브한 어떤 것을 넘어서는 새로운 디지털 매체를 통한 스토리텔링의 재창조를 대화식 드라마이자 미래의 서사양식으로 제시했다.^[10] 이러한 논의를 발전시켜 마이클 마티어스(Michael Mateas)는 대화식 드라마를 컴퓨터에 의해 통제받는 캐릭터가 거주하는 극적이고 흥미로운 가상세계로, 이 속에서 사용자는 1인칭 시점으로 이야기를 경험한다고 정의했다.^[11]

대화식 드라마에서 사용자들은 이야기의 플롯을 따라 가는 동시에 이야기의 사이사이에 반응해야 한다.^[11] 이를 통해 사용자와의 상호작용성을 이끌어낼 수 있다. 대화식 드라마는 이러한 상호작용성을 갖기 때문에 이야기마다의 사용자의 선호도를 추출하는 것이 가능하다. 이야기마다의 사용자의 선호도를 추출하여 그 선호도를 바탕으로 추천이 가능하면 상호작용성과 서사경험의 부조화를 줄일 수 있다.

2. 특성 추출 알고리즘

특성 추출(Feature Extraction)은 알고리즘 적용 대상인 입력 데이터가 처리하기에 너무 거대하고 데이터 내부에도 중복이 매우 심할 때, 해당 입력 데이터를 상관성 있는 특성들의 집합 형태로 변환하는 것이다. 즉, 특성 추출은 많은 양의 데이터를 정확하게 기술하기 위해 필요한 리소스의 양을 단순화하는 작업을 포함하고 있다.^[12]

특성을 추출하기 위한 방법으로 PCA와 NMF가 사용된다.

가. PCA (Principal Component Analysis)

PCA는 다수의 특성을 가진 고차원 데이터로부터 데이터의 구조를 밝히거나, 데이터의 차원을 낮추는 데 많이 이용되는 다변량 통계 분석 방법이다. 이는 상관행렬(correlation matrix)의 고유벡터(eigen vectors)를 찾아내는 문제로 행렬 연산으로 찾아내는 방법과 신경망 등을 사용하여 반복적으로 찾아내는 방법 등이 있다.^{[4][13]}

PCA에서는 각 특성에 가중치를 주어 합성을 함으로써 주성분을 구할 수 있다. 그 때 원래 특성이 가지고 있는 정보를 최대한 이용하여 개체간의 분산이 최대가 되도록 가중치를 붙인다. 원래의 특성을 가지는 주성분이 다수 존재하는 경우에는 각각의 주성분간에 상관(correlation)이 없도록, 즉 서로 다른 주성분간의 공분산이 0이 되도록 결정한다. 이들의 관계는 식 (1)과 같이 표현할 수 있다.^[14]

$$\begin{aligned} Z_1 &= a_{11}x_a + a_{12}x_2 + a_{13}x_3 + \dots + a_{1n}x_n \\ Z_2 &= a_{21}x_a + a_{22}x_2 + a_{23}x_3 + \dots + a_{2n}x_n \\ Z_3 &= a_{31}x_a + a_{32}x_2 + a_{33}x_3 + \dots + a_{3n}x_n \\ &\vdots \\ Z_m &= a_{m1}x_a + a_{m2}x_2 + a_{m3}x_3 + \dots + a_{mn}x_n \end{aligned} \quad (1)$$

여기서, $Z_1 \sim Z_m$ 은 주성분, $x_1 \sim x_n$ 은 원래의 변수, $a_{11} \sim a_{mn}$ 은 가중치이다. 분석결과에 의해, 각 주성분의 고유치가 1 이상 또는 누적기여율이 70%를 넘는 것을 기준으로 하여 주성분을 선택한다.^[15]

이러한 PCA는 p개의 변수로 구성된 자료로부터 제1 주성분부터 제p주성분까지 p개의 주성분(=가중합계) 및 각 주성분의 가중치 벡터를 찾는 분석이라고 할 수 있다. 각 p주성분의 내용은 표 1과 같다.

표 1. 주성분의 내용
Table 1. Contents of Principal Component

제 1 주성분	분산이 가장 큰 가중 합계
제 2 주성분	(제 1 주성분과 상관관계가 없는) 분산이 두 번째로 큰 가중합계
제 3 주성분	(제 1 주성분 및 제 2 주성분과 상관관계가 없는) 분산이 세 번째로 큰 가중합계

나. NMF(Non-negative Matrix Factorization)

NMF는 인간이 객체를 인식할 때 객체의 부분정보를 조합해서 인식하는 것에 착안하여, 객체정보를 부분정보인 의미 특징(semantic feature)과 의미 변수(semantic variable)로 나누어 표현한다. 즉, 하나의 객체정보를 비음수로 구성된 두 개의 부분 정보로 인수분해 하는 방법을 말한다. NMF의 목적은 거대한 객체정보를 공통 특성을 포획하여 보다 작은 부분 정보로 줄이는 데 있다. 이러한 부분정보의 조합을 통해 전체 객체를 표현함으로써 대량의 정보를 효율적으로 표현 하는 방법이다.^{[5][6][7]}

NMF의 연산 과정은 식 (2)와 같다.

$$R = W \times H \tag{2}$$

NMF는 식 (2)의 n*m 행렬 R을 W, H 행렬로 인수분해 한다. W는 n*m' (m' < m), H는 m'*n (m' < m) 인 비음수 행렬이다.^[2]일반적으로 행렬의 비음수 행렬 인수분해 과정은 행렬 W와 H를 반복적으로 갱신하여 행렬 R과 W×H간의 거리를 최소화 하는 방향으로 근사한다. 따라서 어떠한 거리 함수 혹은 목적 함수를 적용할 것인가에 따라 성분 값 갱신 식이 달라진다.^[16]

III. 시스템 설계

3장에서는 시스템 설계를 위한 시스템의 구조와 알고리즘에 대해 기술한다. 먼저 시스템의 흐름을 설명하기 위해 시스템의 구조를 명시하였고, 그 후 구현을 위한 알고리즘을 제시하였다.

1. 시스템 구조

그림 1의 다이어그램은 본 논문이 제안하는 대화식 드라마 스토리 경로 추천 시스템의 구조이다.

먼저 훈련 데이터를 만들기 위해 사용자에게 대화식 드라마를 모바일 애플리케이션을 통해 보여주고, 각각의 사용자들이 자신의 선호도에 맞게 스토리의 경로를 선택한다. 본 논문의 연구에 사용된 대화식 드라마의 스토리는 그림 2와 같은 트리의 구조로 진행되고, 그림 3과 같은 UI를 가진다. 모든 스토리는 그림 2의 루트 노드에서 시작하여, 하나의 리프 노드로 끝이 난다. 노드는 총 47개로 구성되고, 각 노드는 스토리가 진행되는 과정을 보여주는 스토리 집합을 표현한다. 예를 들어 노드 2는 노드 1의 내용과 사용자가 선택한 스토리 경로를 통해 보여지는 스토리의 전환점(plot point)이다.

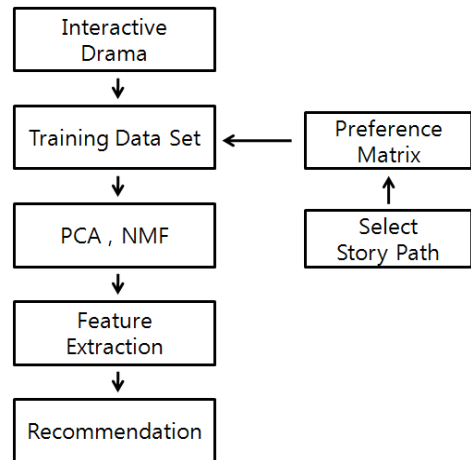


그림 1. 대화식 드라마의 스토리 경로 추천 시스템의 다이어그램
Fig. 1. Diagram of Story Path Recommendation System of Interactive Drama

와 같은 네 개의 갱신 행렬을 생성한다. 그리고 행렬 W를 갱신하기 위해 행렬 W 내의 모든 값을 식 (3) 내의 대응하는 값과 곱하고 식 (4) 내의 대응하는 값으로 나눈다. 동일하게, 행렬 H를 갱신하기 위해 행렬 H 내의 모든 값을 식 (5) 내의 값과 곱하고 식 (6) 내의 값으로 나눈다. 이 과정을 행렬 R과 행렬 $W \times H$ 의 차이가 0이 될 때까지 반복한다.

증배 갱신 규칙 알고리즘은 Python으로 구현된 모듈을 사용하였다. 그림 5는 증배 갱신 규칙 알고리즘을 Python으로 구현한 소스의 일부이다.

```

for i in range(iter):
    wh = w*h

    cost=difcost(v, wh)

    if i%10==0 : print cost

    if cost==0: break

    hn=(transpose(w) * v)
    hd=(transpose(w) * w * h)

    h=matrix(array(h) * array(hn) / array(hd))

    wn=(v * transpose(h))

    wd=(w * h * transpose(h))

    w=matrix(array(w) * array(wn) / array(wd))

return w,h
    
```

그림 5. 증배 갱신 규칙의 Python 소스 일부
Fig. 5. Some Python source of Multiplicative update rules Algorithm

IV. 실험 및 결과

본 논문에서는 그림 2와 같이 노드 47개로 구성된 대화식 드라마의 스토리를 이용하여 사용자 20명을 대상으로 훈련 데이터를 만들고, 훈련 데이터를 통해 추출한 선호도 특성을 기반으로 같은 구조의 스토리를 이용하여 새로운 사용자 40명에게 실험을 진행하였다.

먼저 선호도 행렬과 그 행렬에 따른 PCA, NMF를 통해 훈련 데이터를 만들어 사용자들의 특성을 파악한다. 그 후 훈련 데이터를 통해 나타난 사용자들의 특성을 바

탕으로 40명의 새로운 사용자에게 추천을 하여 어떤 알고리즘이 더 정확한 추천을 제공하였는지 확인한다.

1. 선호도 행렬

그림 6은 사용자 20명에게 대화식 드라마를 보여 준 후 얻은 스토리의 경로 선호도 행렬의 일부이다. 대화식 드라마의 구조는 트리 형태로 구성이 되어있기 때문에, 선택되지 않은 스토리 경로가 존재할 수밖에 없다. 선택되지 않은 스토리 경로는 선호하지 않는 것으로 보고 선호도를 0으로 표시하였다.

	User 1	User 2	User 3	User 4	User 5	User 6	User 7	User 8	User 9	User 10	User 11	User 12	User 13	User 14	User 15	User 16	User 17	User 18	User 19	User 20
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2	0	1	0	1	1	0	1	1	0	0	1	0	1	1	0	0	1	1	0	0
3	1	0	1	0	0	1	0	0	1	1	0	1	0	0	1	1	0	0	1	1
4	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
5	0	1	0	1	0	0	1	1	0	0	1	0	0	1	0	0	1	1	0	0
6	1	0	0	0	0	1	0	0	1	1	0	1	0	0	0	0	0	0	0	1
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
11	0	1	0	0	0	0	1	1	0	0	0	0	0	1	0	0	1	1	0	0
12	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1
14	1	0	0	0	0	1	0	0	1	1	0	0	0	0	0	0	0	0	0	1

그림 6. 선호도 행렬 결과 일부
Fig. 6. Some results of Preference Matrix

2. 훈련 데이터

훈련 데이터는 그림 6의 선호도 행렬을 통해 생성하였고, 그 훈련 데이터를 PCA와 NMF를 이용하여 선호도 특성을 추출하였다.

가. PCA

PCA의 실험 결과는 2가지의 행렬로 나타나는데, 그 행렬을 다이어그램으로 표현하였다. 두 개의 다이어그램 모두 산출된 주성분을 해석하기 위하여 필요한 것들로, 가로축은 제 1 주성분, 세로축은 제 2 주성분으로 표시한다.

먼저 그림 7은 성분 도표를 표현한 것으로, 산출된 주성분의 식을 시각화한 것을 말한다. 다음으로 그림 8은 주성분 득점을 산점도로 나타낸 것이다. 주성분 득점은 주성분으로 본 개개 표본의 값을 말한다.^[15] 제 1 주성분과 제 2 주성분의 누적 기여율이 75%이므로 의미 있는 결과로 해석이 가능하다.

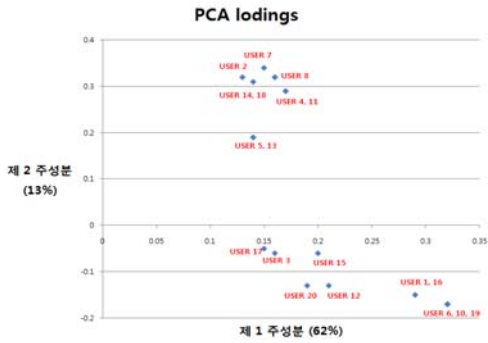


그림 7. 성분 도표
Fig. 7. Component Diagram

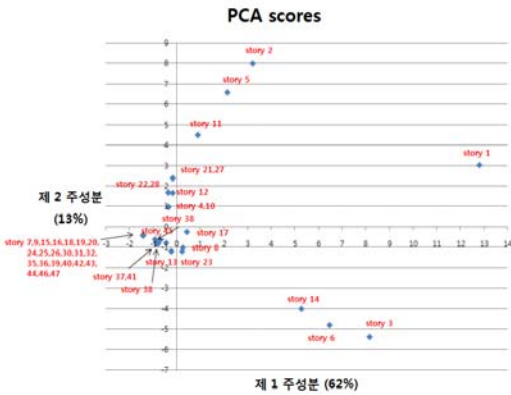


그림 8. 주성분 득점 산점도
Fig. 8. Scatter Diagram of Principal Component Scores

그림 7의 제 1 주성분은 각 사용자들이 모두 플러스로 평가되고 있어 종합평가의 시점을 제공한다. 그러나 제 2 주성분은 사용자 번호가 2, 4, 5, 7, 8, 11, 13, 14, 18인 사용자들만 플러스로 평가되고 있어 사용자들의 특성에 따른 분류가 제공된다.

이러한 주성분 득점에 따른 분류를 통해 그림 8과 같이 각각의 스토리 특징 파악이 가능하다. 그림 8의 제 1 주성분과 제 2 주성분 모두에서 마이너스 평가를 받은 스토리들은 사용자가 선호하지 않은 스토리로 파악하고 추천에서 제외한다. 또한 그림 8에서 제 2 주성분의 평가가 플러스인 스토리들은 그림 7에서 제 2 주성분의 평가가 플러스인 사용자가 선호한다는 분석이 가능하다. 뿐만 아니라 그림 7에서 제 2 주성분의 평가가 마이너스인 스토리들은 그림 8에서 제 2 주성분의 평가가 마이너스인 사용자가 선호한다는 분석이 가능하다. 이러한

분석을 토대로 특성에 따른 스토리 경로를 추천한다.

나. NMF

NMF의 실험 결과 역시 2개의 행렬로 나타난다. 첫 번째 행렬은 행이 스토리 번호, 열이 특성인 행렬로 특성에 따른 각 스토리의 선호도를 나타낸다. 두 번째 행렬은 행이 특성, 열이 사용자인 행렬로 특성에 따른 각 사용자의 선호도를 나타낸다. 본 논문에서는 2개의 특성이 나오도록 실험을 진행하였다.

그림 9는 첫 번째 행렬에서 각 특성에 가장 높은 선호도를 가진 스토리의 번호 5개와 두 번째 행렬에서 각 특성에 가장 높은 선호도를 가진 사용자 3명을 뽑아 분류한 것이다.

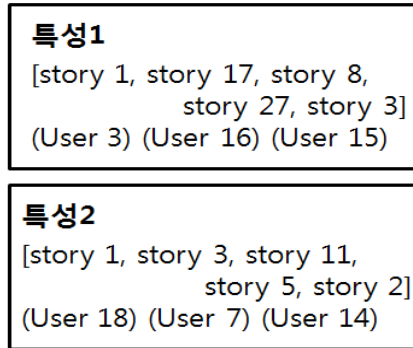


그림 9. NMF을 이용한 특성 추출
Fig. 9. Feature Extraction Using NMF

3. 실험 결과

PCA와 NMF을 통해 추출된 특성을 이용하여 스토리 경로를 추천하였다. 실험 결과에서는 PCA와 NMF를 통해 나타난 선호도 특성에 따라 추천한 후, 두 알고리즘의 추천 성공률을 비교하여 어떤 알고리즘이 더 정확하게 추천하였는지 확인한다. 실험은 40명의 새로운 사용자들 대상으로 진행하였다.

가. PCA

PCA를 이용해 얻은 사용자의 스토리 경로 선호도 특성을 바탕으로 그림 10과 같이 추천하였고, 그 결과 표 2와 같은 추천 성공률을 보였다. 그림 10의 숫자는 스토리 번호에 해당한다.




그림 10. PCA를 이용한 추천 스토리 경로
Fig. 10. Recommendation Story Path Using PCA

표 2. PCA의 추천 성공률
Table 2. The success rate of recommending of PCA

추천스토리	추천 성공률	
1 -> 2 -> 5 -> 11	30명 / 40명	75 %
1 -> 3-> 6-> 14		

나. NMF

NMF를 이용해 얻은 사용자의 스토리 경로 선호도 특성을 바탕으로 그림 11과 같이 추천하였고, 그 결과 표 3과 같은 성공률을 보였다. 그림 11의 숫자는 스토리 번호에 해당한다.




그림 11. NMF를 이용한 추천 스토리 경로
Fig. 11. Recommendation Story Path Using NMF

표 3. NMF의 추천 성공률
Table 3. The success rate of recommending of NMF

추천스토리	추천 성공률	
1 -> 2 -> 5 -> 11	25명 / 40명	62.5 %
1 -> 3 -> 8 -> 17 -> 27		

실험의 결과는 위의 표2, 표3를 통해 알 수 있다. PCA를 이용한 스토리 경로 추천 성공률은 실험 사용자 40명 중 30명으로 75%, NMF를 이용한 스토리 경로 추천 성공률은 실험 사용자 40명 중 25명으로 62.5%로 나타났다. 실험을 통해 NMF보다 PCA를 통해 보다 더 정확한 스토리 경로 추천이 가능한 것을 확인할 수 있다.

V. 결론

본 논문에서는 PCA와 NMF를 이용한 대화식 드라마의 스토리 경로 추천 시스템을 구현하였고, 실험을 통해 PCA를 이용해 얻은 선호도 특성으로 추천한 결과 추천 성공률 75%, NMF를 이용해 얻은 선호도 특성으로 추천한 결과 추천 성공률 62.5%를 얻어냈다.

향후 과제로는 다양한 사용자 군에 따른 스토리 경로 선호도를 통해 각 군집에 맞는 추천 시스템을 구현하고, PCA와 NMF 이외의 베이지안 분류기나 군집 알고리즘 등을 이용한 특성 추출 알고리즘을 적용해 더 높은 성공률을 가질 수 있는 알고리즘이 있는지 살펴본다.

참고 문헌

- [1] Yoon H J, A study on story generation model of interactive drama, Journal of Korean Society for Computer Game , vol. 3, NO 21, 2010 June.
- [2] Hong Yu and Mark O. Riedl, A Sequential Recommendation Approach for Interactive Personalized Story Generation, Proceedings of the 11th International Conference on Autonomous Agents and Multiagent Systems, Valencia, Spain, 2012 June.
- [3] David K. Elson and Mark O. Riedl, A Lightweight Intelligent Virtual Cinematography System for Machinima Production, Association for the Advancement of Artificial Intelligence, 2007.
- [4] Erkki Oja, Principal components, minor components, and linear neural networks, Neural Networks, vol. 5, pp. 927-935, 1992.
- [5] Daniel D. Lee and H. Sebastian Seung, Learning the parts of objects by non-negative matrix factorization, Nature, vol. 401, pp. 788-791, 1999.
- [6] Daniel D. Lee and H. Sebastian Seung, Algorithms for Non-negative Matrix Factorization, In Advances in Neural Information Processing System, vol. 13, pp. 556-562, 2001.
- [7] D. K. Lee, J. H. Kwon, "Social Search Algorithm considering Recent Interests of User", Journal of

- Korean Institute of Information Technology, vol. 9, issue 4, pp. 187-194, Apr 2011
- [8] Brenda Laurel, Reassessing Interactivity, The Journal of Computer Game Design, vol. 1, No. 3, 1987 October-November.
- [9] Brenda Laurel, Computer as Theatre, Addison Wesley Longman, 1993.
- [10] Janet Murray, Interactive Storytelling, An Graphics, pp. 310, 2001.
- [11] Michael Mateas, Interactive Drama, Art and Artificial Intelligence, School of Computer Science Carnegie Mellon University, pp. 3, 2002.
- [12] Shailesh Kumar, Joydeep Ghosh, and Melba M. Best-Bases Feature Extraction Algorithms for Classification of Hyperspectral Data, IEEE Transactions on geoscience and remote sensing, Vol. 39, No. 7, 2001 July.
- [13] Michael E. Tipping and Christopher M. Bishop, Probabilistic Principal Component Analysis, Journal of the Royal Statistical Society, Vol. 61, No.3, pp 611-622, 1999.
- [14] Henning Risvik, Principal Component Analysis (PCA) & NIPALS algorithm, 2007 May.
- [15] Toby Segaran, Programming Collective Intelligence: Building Smart Web 2.0 Applications, O'REILLY, pp. 300-302, 2007.

저자 소개

이 연 창(준회원)



• 을지대학교 의료IT마케팅학과 재학생

장 재 희(준회원)



• 을지대학교 의료IT마케팅학과 재학생

김 명 관(정회원)



- 1981년 3월 ~ 1985년 2월 : 숭실대학교 전자계산학과 학사
- 1985년 3월 ~ 1987년 2월 : 숭실대학원 전자계산학과 석사
- 1996년 9월 ~ 2004년 2월 : 숭실대학원 컴퓨터학과 박사
- 1989년 8월 ~ 1993년 2월 : 한국전자통신연구소 지식처리연구실 유저인터페이스 개발팀장
- 1993년 3월 ~ 2007년 2월 : 서울보건대학 컴퓨터정보과 부교수
- 2007년 3월 ~ 현재 : 을지대학교 의료IT마케팅학과 부교수

<주관심분야 : 인공지능, 자연어처리, 질의응답시스템, 시맨틱 웹>