

멀티 모달 인터페이스 기반 플레이어 얼굴 표정 분석 시스템 개발

정장영*, 김영빈**, 이상혁**, 강신진*

홍익대학교 게임학부*, 고려대학교 컴퓨터학과**

{akillness38, ybkim.visualinformation, monthae89}@gmail.com, directx@hongik.ac.kr

Expression Analysis System of Game Player based on Multi-modal Interface

Jang-Young Jung*, Young-Bin Kim**, Sang-Hyeok Lee**, Shin-Jin Kang*

School of Games, Hongik University*, Dept. of Computer Science, Korea University**

요약

본 논문은 게임을 수행하는 개별 사용자의 특별한 행동 탐지를 효율적으로 수행하는 시스템을 제안한다. 제안하는 시스템은 일반적인 게임 플레이 환경에서 비 침투적 방법을 통해 포착 가능한 사용자 특징과 반복적인 패턴에 기반을 두어 특이 행동 탐지를 한다. 본 논문에서는 표정과 사용자 움직임과 같이 관찰되는 자료를 분석하기 위해 카메라를 사용했다. 게다가 반복 행동 탐지를 위해 게임 사용자로부터 멀티 모달 데이터를 사용하여 고차원의 행동 분석하기 위해 사용했다. 특이 행동 탐지에 효과적인 Support Vector Machine 을 사용했으며, 특이 행동 탐지 수행의 유용성을 평가하여 약 70% 확률로 탐지하는 이상 행동 탐지 재현율을 보였다. 또한 반복 행동 분석이 가능함을 보였다. 제안된 기법을 사용하였을 때 PC 환경에서 제공하는 모든 콘텐츠의 분석에 대한 피드백과 정량화하는데 도움이 될 수 있다.

ABSTRACT

In this paper, we propose a method for effectively detecting specific behavior. The proposed method detects outlying behavior based on the game players' characteristics. These characteristics are captured non-invasively in a general game environment and add keystroke based on repeated pattern. In this paper, cameras were used to analyze observed data such as facial expressions and player movements. Moreover, multimodal data from the game players was used to analyze high-dimensional game-player data for a detection effect of repeated behaviour pattern. A support vector machine was used to efficiently detect outlying behaviors. We verified the effectiveness of the proposed method using games from several genres. The recall rate of the outlying behavior pre-identified by industry experts was approximately 70%. In addition, Repeated behaviour pattern can be analysed possible. The proposed method can also be used for feedback and quantification about analysis of various interactive content provided in PC environments.

Keywords : Game, Outlier Behaviour, Multi-Modal Interface, Expression, ANN, SVM
(게임, 특이 행동, 멀티 모달 인터페이스, 표정, 인공 신경망, SVM)

Received: Mar, 10, 2016 Revised: Apr, 14, 2016

Accepted: Apr, 16, 2016

Corresponding Author: Shin-Jin Kang(Hongik University)

E-mail: directx@hongik.ac.kr

ISSN: 1598-4540 / eISSN: 2287-8211

© The Korea Game Society. All rights reserved. This is an open-access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>), which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

게임을 개발하면서 일반적으로, 게임 제작자의 입장에서 가장 중요한 것은 사용자가 개발 의도와 맞는 반응을 보일 것인지를 예측하는 것이다. 이러한 목적을 위해서 대형 게임 회사에서는 Fun QA(Quality Assurance)팀을 구성하여 운영하곤 한다. Fun QA팀은 게임 개발 단계에서부터 인적 자원을 활용하여 꾸준히 사용자의 반응을 확인한다. 이러한 관점에서 개발자들은 게임 제작에서 사용자가 적절한 시기에 게임 내 환경에 대하여 재미, 집중, 몰입, 놀람 등의 반응을 보이길 원하기 때문이다[1,2,3,4].

이러한 감정 관찰을 위한 방법으로 비 침투적이고, 저 비용이며 확장 가능한 시스템은 제안되어 왔으며, 생리적 신호의 처리에 기초하여 감정 인식 시스템을 제공하는 연구가 진행되어왔다[5,6].

사용자의 반응을 바탕으로 대규모 인원이 게임 개발 단계뿐 아니라 출시 후에도 게임을 재설계 하는데, 게임 사용자의 재이용 요인이 게임 개발 및 마케팅 활동에 적합한 시사점을 제공하기 때문이다. 하지만, 장기적으로 투입되고 운영하는 것에는 많은 자원을 필요로 하는 문제점이 있다[7].

게임 개발 과정에서 소비자를 상대로 하는 베타 테스트의 비중이 점차 증가하고 있다. 베타 테스트는 단순히 오류 수정의 범주가 아니라 게임에 대한 소비자의 반응을 즉각적으로 살피고 게임에 반영할 수 있다는 점에서 매우 유용하기 때문이다[8]. 그렇지만, 인디 게임 회사 등 소규모 게임 회사에서는 활용이 어려운 문제와 개발자의 제작 의도를 사용자가 적시에 반응하고 있는지를 파악하더라도 정량화 된 자료가 아닌 수기로 작성된 자료에 대한 신뢰도 또한 문제가 될 수 있다. 개발자의 입장에서 파악하기는 쉽지 않은 문제이다.

이렇게 짧은 시간 동안에 거대한 정보의 흐름으로부터 전체 규모의 대부분 중요한 요소를 추출하기 위해 시각적인 시스템을 제안하며, 중소기업과 대기업에서 반복 게임사용 관점의 혁신적인 행동

규모를 설계한 이론적인 연구를 바탕으로 이러한 문제를 해결하는 것은 개발자와 사용자가 의도하는 게임을 개발하는 확실한 단계라 할 수 있다[9,10].

2. 본론

2.1 기존 연구

사용자의 반응을 확인하기 위한 기존 게임 사용자 조사와 사용자 실험 관련 조사의 경우 사용자가 보고 측정(인터뷰, 질의질문, 집중 그룹 등)에 의존하거나 실험자의 관찰 비디오 분석 보고서를 통해 이루어지는 경우가 많다[11]. 이러한 연구의 경우 수행하기 쉽고, 사용자의 데이터가 쌓일수록 견고하고 올바른 반응 유추에 도움이 된다. 하지만 이러한 연구의 경우 사용자 자가 보고서를 위해 사용자가 게임 플레이 외의 시간을 투자해야 하며 사용자의 주관성이 개입될 가능성이 높고, 사용자가 보고서를 분석하는데 많은 시간이 소요된다.

게임 내에서 사용자 데이터를 수집하는 방법에 대한 연구는 게임 시장의 발전과 더불어 점점 더 많이 진행되고 있는 분야이다. 사용자 데이터의 경우 크게 설문조사 등에 기반을 둔 의견 데이터와 게임 상에서 얻어지는 사용자의 플레이 데이터, 로그 데이터 등으로 분류하여 수집하곤 한다[12]. 일반적으로 이러한 데이터를 얻기 위해서는 이러한 목적을 가진 Crawling tool을 활용하거나, 수집할 데이터의 형태와 목적에 맞추어 로그 데이터를 얻어 활용하거나 혹은 사용자를 직접 관찰하여, 거기서 발생하는 사용자의 행동을 분석하기도 한다 [13,14,15,16]. 행동을 분석하기 위한 방법으로 키보드와 마우스를 이용해 상호적인 행동을 통한 개인의 특성을 예측하는 연구를 통해, 행동 해체 시점을 교사 학습 알고리즘을 사용, 관측하여, 행동 해체 시점의 정확도를 높이면서, 실제 종료와 예측된 종료의 연관성을 활용한다[17,18]. 기존 스트레스와 관련된 언어적 형태와 키스트로크를 사용한 실험적인 연구를 토대로, 키보드 타이핑 정확도 비율, 키

스트로크 길이, 키 입력 대기 시간에서 작성 효과가 있다는 것을 보여주었기 때문에 이를 활용한다 [19,20]. 우리의 연구는 기존 로그 데이터를 활용하는 연구들을 확장하여, 키보드와 마우스 입력, 얼굴 특이점, 표정, 음성과 같은 사용자 로그 데이터를 활용하고자 한다.

본 논문에서는 비 침투적인 방식으로 반복 패턴에 기반을 두어 사용자의 특이 행동을 탐지하는 시스템을 제안한다. 제안하는 방법은 웹캠 등의 PC 카메라를 바탕으로 하여 사용자 관찰과 사용자의 로그 데이터 등 멀티 모달 인터페이스를 통해 고차원의 사용자 데이터를 수집하고, 반복적인 게임을 플레이하는 사용자에게 대해 효율적으로 분석하여 반복 행동 탐지를 할 수 있다. 사용자의 행동을 관찰하고 특이 행동을 탐지하는데 있어서는, 사용자 자가 보고서 측정(인터뷰, 질의질문 등)과 같은 추가적인 데이터를 요구 하지 않으며, 개발자의 분석 시간을 최소화하도록 자동으로 데이터를 분석하는 기법을 제안한다.

2.2 시스템 정의

본 논문의 방법은 다차원의 특징점으로부터 사용자의 플레이 경험 분석에 필요한 상위 레벨의 감성적 피드백을 탐지하고자 한다. 본 시스템에서 탐지하고자 하는 플레이어의 행동 상태는 특이 행동과 키스트로크 패턴이다. 본 논문에서는 이에 대해 사전 정의했다.

개발자가 의도한 방향에 맞추어 공통적으로 나타나는 사용자의 반응이 있을 것이라고 가정하고, 이러한 공통적인 사용자의 반응을 일반적인 플레이 상황에서 나오지 않는 이상 행동으로 정의하였다. 본 논문에서는 공통적인 사용자 반응 추출을 위한 실험을 진행하였다.

주로 나타는 사용자의 행동을 정리해 보면, 몸의 움직임이 앞, 뒤로 혹은 좌우로 커짐, 표정이 변함, 눈을 크게 뜸, 눈썹이 위로 올라감, 입이 커짐, 눈 깜빡임의 변화, 짧은 소리를 냄 등의 현상이 생기는 것을 확인할 수 있었다. 해당 실험 결과에 대해

서는 [Table 1] 에서 확인할 수 있다. 이러한 행동들은 독립적으로 나타나는 경우도 있지만, 대부분 복합적으로 나타나기 때문에 이러한 경우를 자동으로 확인하는 것은 어려운 문제이다.

[Table 1] The User's Reactions List

List	Description
Facial Feature point	24's Facial Feature Points Action Variation
Expression	Neutral, Happy, Sad, Angry, Surprised, Disgusted, Fear
Keyboard	Keyboard Usage
Mouse	Mouse Usage, Mouse's Range
Voice	User's Voice

사용자의 행동을 바탕으로, 복합적인 결과에 대한 의미를 찾기 위한 키보드 사용량에 대한 키보드 사용 행동군을 [Table 2]와 같이 정리했다.

[Table 2] The Keystroke List for Repeated Pattern Detection

Candidate	Action	Key Mapping
Arrow Keypad	L, R, U, D	Left, Right, Up, Down

2.3 시스템

사용자의 특이 행동을 탐지하기 위해 본 시스템에서는 70개의 입력 파라미터들을 실시간으로 탐지하는 Y. B. Kim[21]의 시스템을 이용했다.

2.3.1 얼굴 특징점 및 사용자 로그 데이터 탐지

얼굴의 특징점은 AAM (Active Appearance Model)을 이용했다[22]. AAM 에 기반을 둔 안면 형태점 검출 연구는 다양하게 이루어지고 있다. 하지만, 우리는 person-independent AAM을 사용하지 않고 generic AAM을 통해 사용자의 얼굴 탐지를 하였다. 눈, 코, 입, 눈썹의 움직임, 눈 깜빡

입과 연관된 70개 특징점의 변화량을 사용하여 학습에 사용하였다. 해당 부분의 구현은 OpenCV를 통해 했다[23].

표정의 경우 ANN(Artificial Neural Network)를 이용하여 만드는 기존 연구에 얼굴 특징점 데이터들을 사용하여 구현했다. ANN을 활용하기 위해서는 적절한 숫자의 노드를 가지도록 층 설정하는 것이 중요하다. 우리는 70개의 얼굴 특징점[Fig. 1]을 24개 그룹으로 다시 나누어 표정 인식에 사용했다[24].

[Table 3]에는 해당 그룹의 경우 표정 변화에 일반적으로 가장 큰 영향을 미치는 특징점들을 통해 구성했다. 해당 그룹에 해당하는 특징점의 움직임 변화량의 합을 학습에 사용했다. 입력 층의 경우 뒤의 24개 집합을 노드로 사용했다. 출력 층의 경우 인식하고자 하는 7가지 표정(무표정, 행복, 슬픔, 화남, 놀람, 거북함, 두려움)으로 구성하였다. 숨은 층의 경우 경험적으로 집합 노드 경험적으로 노드의 개수가 20개 이상일 시 결과 값의 차이가 거의 없는 관계로 20개의 노드로 구성하여 사용하였다. ANN 학습을 수행하기 위한 데이터 셋을 만들었다. Karolinska Institute EMOTION LAB에서 제공하는 표정 데이터 총 140명의 그룹(남자 70명, 여자 70명)의 훈련 데이터를 이용하여 개인 별로 표정 7개에 대한 데이터를 140개씩 산출하여 총 980개의 표정 데이터를 앞의 데이터를 학습에 사용하였다. 해당 데이터 세트에 대하여 10배 교차 검증을 이용하여 정확도가 70% 이상 나오는 것을 확인하였다. 해당 결과를 바탕으로 표정 인식기를 구성하고 사용하였다[25].



[Fig. 1] 24's Input Node Feature Point in 70's Feature Point

[Table 3] 24's Input Node and Node's Mark Definition

Feature	Mark
1-3-5	RightEyebrow(eintire edge)
3-4-5	RightEyebrow(start edge)
2-3-4	RightEyebrow(middle edge)
1-2-3	RightEyebrow(end edge)
6-8-10	LeftEyebrow(eintire edge)
6-7-8	LeftEyebrow(start edge)
7-8-9	LeftEyebrow(middle edge)
8-9-10	LeftEyebrow(end edge)
11-12-14	RightEye(up edge)
11-13-14	RightEye(down edge)
12-14-13	RightEye(start edge)
12-11-13	RightEye(end edge)
15-16-18	LeftEye(up edge)
15-17-18	LeftEye(down edge)
16-15-17	LeftEye(start edge)
16-18-17	LeftEye(end edge)
20-22-21	Nose(top directedge)
23-25-24	Nose(under widthedge)
20-23-25	Nose(right edge)
20-24-25	Nose(left edge)
27-26-29	Mouth(right edge)
27-28-29	Mouth(left edge)
26-27-28	Mouth(top edge)
26-29-28	Mouth(under edge)

사용자의 키보드, 마우스 움직임 및 사용량에 대한 로그 데이터는 사용자의 현재 상태를 파악하는데 큰 도움이 된다. 본 논문에서는 시스템이 동작하는 동안 발생하는 사용자의 키보드 입력과 마우스 동선 및 입력량을 확인하도록 하였다. 키보드 데이터의 경우 실시간으로 사용자의 입력 상황을 파악하여 의도한 명령 조합을 하고 있는지 파악할 수 있을 뿐만 아니라 다른 데이터와의 비교를 통하여 특이 행동을 찾아, 사용자가 겪고 있는 문제를 발견할 수 있다. 또한, 사용자의 대화 로그를 통해서 텍스트 마이닝을 통해 의미 있는 데이터를 발견할 수 있다. 본 논문에서는 게임 플레이에 필요한 명령어들의 집합에서 반복적인 키 패턴이 발생하는지에 중점을 두었으며, 실제로 이루어지는 채팅 데이터에 대해서는 다루지 않았다. 마우스 데이터의 경우 사용자의 마우스 이동 동선 파악이 가장 큰 목적이며, 이를 통해 부가적으로 사용자의 주된 시점을 간접 측정하면서 사용자의 주시 수준을 확인할 수 있다. 본 논문에서는 마우스의 이동 거리 및 입력량에 기반을 두어 게임 플레이 외의 행동이 발생하는지를 파악하고자 하였다.

2.3.2 특이 행동 분류기

특이 행동 분류기의 경우 개인화하여 동작하도록 설계하였다. 특이 행동 분류기에 추가적으로 화살표 방향키 키스트로크 데이터 로그를 추가했다.

이러한 과정을 위한 학습 데이터를 습득하기 위하여 우리는 사전에 미리 게임을 플레이하여 얻어진 사용자의 데이터를 활용하였다. 해당 게임에 대해서는 사전에 정의된 특이 행동 발생 예상 구간을 설정해 두고 해당 부분에서 나타나는 생체 신호 및 사용자 로그 데이터를 학습 데이터로 삼았다. 특이 행동 발생 예상 구간의 경우 해당 분야의 전문가들을 통해 표시 하였다.

해당 영상을 바탕으로 위에서 설명한 방법을 기반으로 하여 생체 신호를 500ms 단위로 탐지하였다. 탐지에 앞서 5,000ms 간 사용자의 초기 상태

를 저장하였다. 초기 상태로부터 매 500ms 단위마다 24개 얼굴 특징점 집합의 상대적인 각도 변화량 값을 학습에 사용하였다. 추가적으로 표정, 눈 깜빡임 횟수, 사용자 로그 데이터, 음량이 학습에 사용되었다. 학습군 구성을 위해서 특이 행동이 발생한 지점으로부터 2,500ms 지나는 부분까지 데이터를 이상 행동 부분으로 표기하여 사용하였다. 그 외의 부분에서 나타나는 부분에 대해서는 일반적인 행동 부분으로 표기하여 사용했다. 특이 행동으로 표시한 부분 이외에서 이상 행동이 발생할 수 있고, 이러한 부분이 학습의 정확도를 떨어뜨릴 수 있지만, 우리의 경험적 실험으로 평가했을 때 영향력은 미미했다.

추출한 파라미터에 대하여 미리 표시된 이벤트에 해당하는 사용자 파라미터와 이외의 프레임에서 추출되는 사용자 파라미터를 바탕으로 Support Vector Machine(SVM)을 통해 학습을 진행하였다. 우리는 다양한 사용자의 특이 행동을 분석하려는 것에 목적이 있는 것이 아니라, 특이 행동 구간 내에 키 패턴을 탐지하는 것이 목표이기 때문에 특이 행동 탐지에 SVM을 사용하는 것이 적합하다고 판단했다.

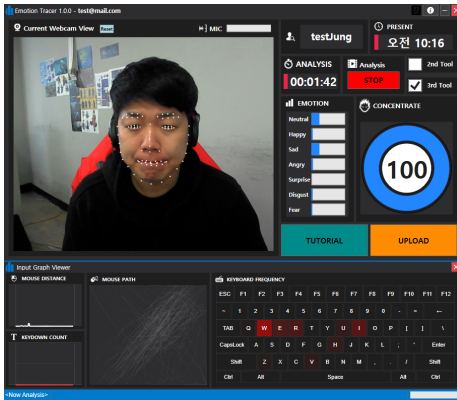
SVM의 경우 소수의 특이 행동 데이터와 다수의 행동 데이터를 기반으로 학습했을 때 분류를 효율적으로 수행했다. 본 논문에서는 LibSVM을 사용했다. 적은 수의 학습데이터를 기반으로 효율이 뛰어나서 본 논문에서는 SVM을 사용하였으나, 다른 이진 분류 학습이나 분류 알고리즘을 사용해도 비슷한 결과를 나타냄을 확인했다[26].

추출한 파라미터에 대하여 이벤트에 해당하는 사용자 파라미터를 바탕으로 화살표 방향키 키스트로크 패턴 탐지에 Apriori Algorithm을 사용하는 것이 적합하다고 판단했다.

3. 실험 결과

3.1 특이 행동 분석

위에서 제안한 방법으로 시스템을 구성하여 실험을 진행했다. [Fig. 2]는 전체 완성된 시스템의 모습이다.



[Fig. 2] View of Multi-Modal Interface

특이 행동 분석 실험은 개인화된 분류기의 성능을 검증하고자 하였다. 실험에는 총 30명의 실험자(남자 15명, 여자 15명, 연령대 23 ~ 31세, 평균 시간 26.8 분)를 모집하여 실험하였다. 실험 참가자 대부분이 5년 이상의 게임 경험을 가지고 있었으며, 주당 평균 5시간 정도의 게임 플레이 시간을 보였다.

실험을 위해 30명의 실험자를 대상으로 사전에 개인화 된 분류기를 학습시켰다. 이를 통해 감성 평가에서 주로 발생하는 개인 간의 편차를 미리 줄이고자 했다. 30명의 실험자를 세 그룹으로 나누어 실험을 진행하였다. 학습에 필요한 데이터 수집 시간에 차이를 두어 그룹 당 20분, 40분, 60분을 설계하였다. 그룹별로 액션 어드벤처 FPS 장르인 Tome Raider 게임을 대상으로 각자 학습된 분류기를 가지고 똑같이 액션 어드벤처 FPS 장르인 Bioshock Infinite, AOS 장르인 League of legends 게임을 각 30분 간 플레이하였다. 여러 장

르의 게임을 다양하게 플레이함으로써, 실험 및 검증을 다양한 방향에서 접근하고자 하였다. 실험 진행은 주변 소음이 차단된 밀폐된 공간 안에서 진행했다.

실험은 실험자를 대상으로 사전에 학습된 개인화된 분류기를 통해 특이 행동 구간 탐지가 제대로 이루어지는지 확인하고자 했다. 개인화된 분류기를 만드는데 사용했던 게임과 같은 장르의 Bioshock Infinite를 플레이 하면서 나타난 특이 행동 구간을 파악하고자 하였다. 전문가들을 통해 수행하는 게임 타임라인에 대하여 특별한 이벤트가 발생하는 구간을 지정해두고, 이러한 구간과 실제 시스템이 예측하는 구간이 어느 정도 매치가 되는지를 확인하였다. 모든 실험에서 미리 정의된 특이 행동 구간 2,500ms 안에 한 번 이상 매치가 이루어질 경우 특이 행동을 예측한 것으로 진행했다. 각자 개인화 된 분류기를 기반으로 특이 행동 구간을 예측하였을 때 그룹별로 조금의 차이가 있었다. 학습데이터 수집을 20분 진행한 그룹의 경우 반응률은 약 74%, 정확도는 약 69% 수준으로 나왔다. 학습데이터 수집을 40분 수행한 그룹의 경우 반응률은 약 77%, 정확도는 71% 수준으로 나왔고, 60분을 수행한 그룹의 경우 반응률은 약 78%, 정확도는 약 71% 수준으로 나왔다. 첫 번째 실험 결과, 학습기간이 길어질수록 조금 더 좋은 결과를 나타내는 것을 확인했으나, 극적인 차이를 보이지 않아 사용 목적에 맞춰 조절할 필요가 있을 것으로 판단된다.

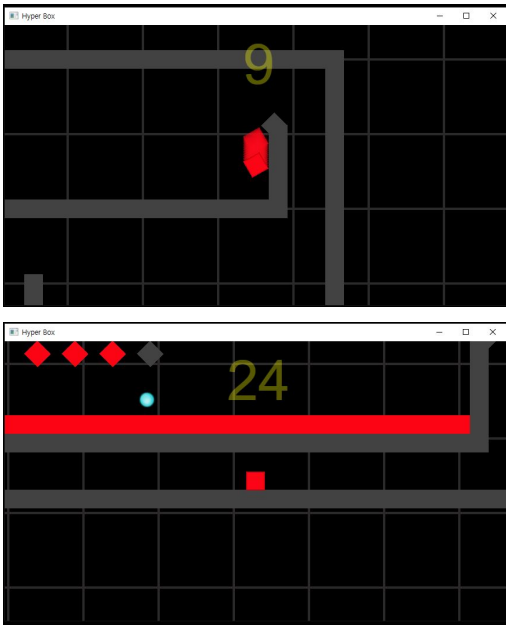
3.2 반복 행동 분석

반복 행동 분석 실험에는 총 7명의 실험자(남자, 연령대 24 ~ 25세, 평균시간 4분17초)를 모집하여 실험하였다. 실험을 위한 게임은 [Fig. 3]에서 보여지는 것과 같이 화살표 방향키 조작으로 제한된 시간(30초)내에 목표 지점까지 도착해야하는 퍼즐 아케이드 장르의 Hyper box 게임을 선정했다.

Hyper box 게임을 플레이 하면서 나타나는 게

임 레벨(1~5레벨)당 화살표 방향키 키스트로크에 대한 정보를 수집했다.

실험은 실험자를 대상으로 멀티 모달 인터페이스 툴을 이용하여 특히 행동구간 내 화살표 방향 키스트로크 입력이 제대로 이루어지는지 확인하고자 했다.



[Fig. 3] 'Hyper Box' User Interface

[Table 4] The Result of Repeated Pattern at Game Level Clear


	According to The Sequence Action (Frequency)						
Lv.1	R (0.81)	U (0.58)	RU (0.46)				
Lv.2	U (0.84)	R (0.74)	L (0.69)	RU (0.62)	LU (0.60)		
Lv.3	L (0.86)	U (0.82)	R (0.79)	LU (0.71)	LR (0.70)	RU (0.69)	LRU (0.60)
Lv.4	R (0.85)	U (0.58)	RU (0.49)				
Lv.5	R (0.77)	U (0.77)	L (0.68)	RU (0.62)	LU (0.62)		

각 레벨을 완수할 때마다 자주 사용되는 키스트로크의 결과를 얻을 수 있었으며, 개인 별 각 레벨을 완수 했을 때에는 키스트로크의 비율이 다양하게


나왔다. 레벨 단위로 그룹을 지었을 때의 전체 키스트로크는 게임을 완수를 성공 했을 때와, 실패했을 때로 나누어, 성공 했을 때의 결과 [Table 4]와 실패 했을 때의 결과 [Table 5]를 얻을 수 있었다. Apriori Algorithm은 반복 적인 키 패턴을 찾기에 적합하기 때문에, 레벨 단위의 전체 그룹에서 얻은 결과 키스트로크가 의미 있다고 판단했다.

[Table 5] The Result of Repeated Pattern at Game Level Fail

	According to The Sequence Action (Frequency)				
Lv.2	R (0.85)	U (0.73)	L (0.68)	RU (0.65)	LU (0.49)
Lv.5	R (0.77)	U (0.77)	L (0.68)	RU (0.62)	LU (0.62)



[Fig. 4] Comparison Failure and Success Rate in Lv.2



[Fig. 5] Comparison Failure and Success Rate in Lv.5

키스트로크의 결과 값은 자주 사용된 키스트로크의 빈도수로, 레벨을 성공했을 때의 키스트로크의 결과 값은 게임 목표를 완수 하는데 초보자에

게 힌트의 요소가 될 수 있을 것으로 판단되며, 레벨을 실패했을 때의 키스트로크의 결과 값과 레벨을 성공 했을 때의 그룹의 키스트로크 결과 값 간의 비교를 실시하였을 때, x축은 행동군, y축은 빈도수로 기준을 두고 막대 그래프 형태로 출력하였다.

[Fig. 4]에 보여지는 Lv.2의 경우, 성공군의 경우 'LU' 키스트로크의 빈도수가 줄어들지 않았지만, 실패군의 경우 'LU'의 빈도수가 상대적으로 약 0.11 정도 떨어짐을 알 수 있었다.

[Fig. 5]에 보여지는 Lv.5의 경우, 성공군과 실패군의 키스트로크 중 'L, RU, LU'의 빈도수에서 차이가 있는 것을 알 수 있었다. 경험적으로 키스트로크의 빈도수가 떨어지는 경우는 다른 키스트로크의 빈도수가 높아지거나 또는 키패드에서 손을 떼고 있는 시간이 빈번히 일어날 경우 생기는 현상이다.

종합적으로 볼 때, Lv.2의 경우 'LU'의 키스트로크외의 다른 키스트로크의 입력이과 일정 시간 간격을 두고 진행하는 것이 게임 목표 수행에 방해적 요소가 되었을 것이라 판단이 되었고, Lv.5의 경우 'L, RU, LU'의 키스트로크외의 다른 키스트로크의 입력과 일정 시간 간격을 두고 진행하는 것이 게임 목표 수행에 도움이 되었을 것이라 판단을 내릴 수 있었다.

4. 결 론

우리는 소규모 인원 실험을 통하여 우리의 시스템이 개별 사용자의 특이 행동 탐지에 효율적일 수 있음을 보였다. 아주 큰 영향을 가진 수치는 아니어도, 이러한 시도는 개발자들의 수동적인 작업을 줄일 수 있는 가능성을 보였으며, 키스트로크의 반복 패턴을 통해 분석이 가능함을 알 수 있었다. 이러한 시도는 게임 내 해당 부분에서 레벨 디자인 개발자의 의도대로 사용자가 행동하고 있는지를 파악할 수 있다. 우리의 시스템을 통해 실제 게임 업계에서 게임성 평가 및 레벨 난이도/밸런싱

조절 등에 활용될 수 있을 것이다.

앞으로 우리는 먼저 계속해서 쌓이고 있는 사용자 로그 데이터를 처리하고, 이러한 데이터들을 바탕으로 시스템의 개선을 이끌어낼 것이다. 이러한 데이터를 활용하기 위하여 현재 supervised learning algorithm에 의존된 시스템을 semi-supervised learning 알고리즘을 이용하도록 개선 할 예정이다. 기존 사용자 로그 데이터 가시화 연구를 통하여 사용자의 상태(death, time taken 등등)를 예측하여, 전문가의 레이블링 단계 없이 특이 행동 구간을 예측하도록 개선할 예정이다. 또한, 현재는 사용자의 키보드, 마우스 입력 로그 데이터가 단순히 사용량에 초점이 맞추어져 있지만, 채팅에 따른 문장 분석이나 반복 패턴 분석을 통해 사용자가 처한 상황을 파악할 수 있도록 개선할 것이다. 추가적으로 게임을 플레이하는 사용자의 집중도를 측정하여 연동하는 것도 전체적인 결과 개선에 도움이 될 것이라 생각한다.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Science, ICT & Future Planning (NRF-2015R1A1A1A05001196)

REFERENCES

- [1] Bauckhage, C., Kersting, K., Sifa, R., Thureau, C., Drachen, A., & Canossa, A. How players lose interest in playing a game: An empirical study based on distributions of total playing times. In Computational Intelligence and Games (CIG), September, pp.139-146, 2012.
- [2] Isbister, K., & Schaffer, N. Game usability: Advancing the player experience. CRC Press. 2008

- [3] Lang, P. J. The emotion probe: Studies of motivation and attention. *American psychologist*, 50(5), pp.372, 1995.
- [4] Sánchez, J. L. G., Vela, F. L. G., Simarro, F. M., & Padilla-Zea, N. . Playability: analysing user experience in video games. *Behaviour & Information Technology*, 31(10), pp.1033-1054, 2012
- [5] Po-Ming Lee, Wei-Hsuan Tsui, and Tzu-Chien Hsiao, A Low-C Scalable Solution for Monitoring Affective State of Students in E-learning Environment Using Mouse and Keystroke Data. Springer-Verlag Berlin Heidelberg. pp. 679-680. 2012.
- [6] K. H. Kim, S. W. Bang, S. R. Kim, Emotion recognition system using short-term monitoring of physiological signals. *Med. Biol. Eng. Comput.* 2004, pp.419 - 427. 2004.
- [7] Ji-Hun Lee, A Study on Factors to Affect Reuse Intention and Conversion Intention by Evaluation after Game Use - with Two FPS Games as a Main Consideration - , *Journal of Korea Game Society*, Vol. 9, No. 6, 2009.
- [8] Bo-Mee Yoo, Seung-Ho Ryu, A Case Study of the Mod: a Developmental Perspective in Game Development Process - Focusing on Customer Involvement - , *Journal of Korea Game Society*, Vol. 9, No. 1, 2009.
- [9] Del Viva MM, Punzi G, Benedetti D Information and Perception of Meaningful Patterns. *PLoS ONE* 8(7): e69154. 2013.
- [10] Pagulayan, R. J., Keeker, K., Wixon, D., Romero, R. L., & Fuller, T. User-centered design in games. *The human-computer interaction handbook: fundamentals, evolving technologies and emerging applications*, pp.883-906, 2003.
- [11] DAOJINFAN, YU SUN, Analysis of Innovation Behavior Impact Based on Repeated Game. *IEEE*. Tianjin University of Technology. 2013.
- [12] El-Nasr, M. S., Drachen, A., & Canossa, A. *Game analytics: Maximizing the value of player data*, Springer, 2013.
- [13] Canossa, A., Drachen, A., & Sørensen, J. R. M. (2011, June). Arrrrggh!!!: blending quantitative and qualitative methods to detect player frustration. In *Proceedings of the 6th International Conference on Foundations of Digital Games*. ACM, June, pp. 61-68, 2011.
- [14] Drachen, A., Thureau, C., Sifa, R., & Bauckhage, C. A comparison of methods for player clustering via behavioral telemetry, 2013.
- [15] Kennerly, D. Better game design through data mining. *Gamasutra*, August, pp.15, 2003.
- [16] Zoeller, G. Game development telemetry. In *Proceedings of the Game Developers Conference*, 2010.
- [17] Iftikhar Ahmed Khan, Osman Khalid, Waqas Jadoon, Rafi Us Shan, Abdul Nasir Khan, Predicting Programmers' Personality via Interaction Behaviour with Keyboard & Mouse. *PeerJ COMSATS Institute of Information Technology*. 2015.
- [18] Caitlin Mills, Nigel Bosch, Art Graesser, Sidney D'Mello, To Quit or Not to Quit: Predicting Future Behavioral Disengagement from Reading Patterns. *Springer International Publishing Switzerland* 2014. S. Trausan-Matu et al. (Eds.), LNCS 8474, pp. 19 - 28, 2014.
- [19] Lisa M.Vizer, LinaZhou, AndrewSears, Automated stress detection using keystroke and linguistic features: An exploratory study. *Int. J. Human-Computer Studies* 67. pp. 870 - 886. 2009.
- [20] Po-Ming Lee, Wei-Hsuan Tsui, Tzu-Chien Hsiao, The Influence of Emotion on Keyboard Typing: An Experimental Study Using Auditory Stimuli. *PLOS ONE* | DOI:10.1371/journal.pone.0129056. 2015.
- [21] YoungBin Kim, Shin Jin Kang, SangHyeok Lee, Jang Young Jung, Hyeong Ryeol Kam, Jung Lee, YoungSun Kim, Joonsoo Lee, Chang Hun Kim, Efficiently detecting outlying behavior in video-game players. *PeerJ reviewing PDF* | (2015:06:5577:2:0:NEW 23 Nov. 2015.
- [22] Cootes, T. F., Edwards, G. J., & Taylor, C. J. Active appearance models. *IEEE Transactions on pattern analysis and machine intelligence*,23(6), pp.681-685, 2001.
- [23] Bradski, G. The opencv library. *Doctor Dobbs Journal*, 25(11), pp.120-126, 2000.
- [24] Karthigayan, M., Rizon, M., Nagarajan, R., &

Yaacob, S. Genetic algorithm and neural network for face emotion recognition. *Affective Computing*, pp.57-68, 2008.

[25] <http://www.emotionlab.se/resources/kdef>

[26] Chang, C. C., & Lin, C. J. LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*,2(3), pp.27, 2011.



정 장 영(Jung, Jang Young)

약 력 : 2014 홍익대학교 게임학부 학사
2014- 홍익대학교 게임공학 석사

관심분야 : 데이터 마이닝, 유저 행동 분석



김 영 빈(Kim, Young Bin)

약 력 : 2010 고려대학교 정보통신대학 컴퓨터학과 학사
2012 고려대학교 정보통신대학 컴퓨터전과통신공학과 석사
2012- 고려대학교 정보통신대학 영상정보처리협동과정 박사 수료


관심분야 : 컴퓨터 그래픽스, 데이터 마이닝, 데이터 사이언스, 게임공학



이 상 혁(Lee, Sang Hyeok)

약 력 : 2014 고려대학교 정보통신대학 컴퓨터학과 학사
2016 고려대학교 정보통신대학 컴퓨터전과통신공학과 석사

관심분야 : 게임 기획, 기계학습, 데이터 마이닝



강 신 진(Kang, Shin Jin)

약 력 : 2011 고려대학교 정보통신대학 컴퓨터학과 이학박사
2003-2006 소니 컴퓨터 엔터테인먼트 코리아
2006-2008 엔씨소프트(NCSOFT)
2008- 홍익대학교 게임학부 조교수

관심분야 : 게임 기획, 컴퓨터 그래픽스, 데이터 마이닝