

Combinando Series Temporales y Clustering para extraer Perfiles Evolutivos de Jugadores

Rafael Vindel, Héctor D. Menéndez ^{*}, and David Camacho

Departamento de Ingeniería Informática. Escuela Politécnica Superior.
Universidad Autónoma de Madrid.

C/Francisco Tomás y Valiente 11, 28049 Madrid, Spain

rafael.vindel@estudiante.uam.es{hector.menendez,david.camacho}@uam.es
<http://aida.ii.uam.es>

Resumen La industria de los videojuegos está especialmente centrada en el entretenimiento del usuario. Es muy importante para estas empresas desarrollar juegos interactivos y de uso sencillo para satisfacer las preferencias de sus clientes. Uno de los principales problemas para los desarrolladores de los juegos es obtener información sobre el comportamiento del usuario durante el juego. Esta información es importante, especialmente hoy en día, porque ayuda a conocer las preferencias de los jugadores. Los desarrolladores podrían aprovechar el perfil de jugador extraído de la partida para adaptar el juego a los diferentes usuarios. Este trabajo trata de hacer frente a este problema. En él, se presenta una metodología basada en el clustering de series temporales para agrupar a los usuarios de acuerdo a la evolución de su aprendizaje. Esta metodología ha sido probada con usuarios reales que han jugado a un juego creado con este propósito, llamado “Dream”.

Keywords: Videojuego, Perfil de Jugador, Evolución de Usuario, Series Temporales, Clustering.

1. Introducción

Las extensiones de los videojuegos se han convertido en un negocio emergente en los últimos años [2]. Por lo general, las diferentes empresas venden fases opcionales, personajes o trajes, para los jugadores más interesados en los juegos. Los jugadores que han sido sumergidos en una experiencia profunda de juego sienten atracción por este contenido extra, sin embargo, hay un elevado número de opciones y esto dificulta al usuario elegir su preferida.

Desde otra perspectiva, también es importante comprender cómo el usuario se adapta al juego durante las distintas partidas. Esta información proporciona un perfil general de los jugadores lo que permite a los desarrolladores ajustar el juego a un perfil de usuario concreto, por ejemplo, en función de su edad, sexo,

^{*} Este trabajo ha sido parcialmente financiado por: El Ministerio Español de Educación y Ciencia bajo el proyecto TIN2010-19872 y por el proyecto Savier an Airbus Defense & Space project (FUAM-076914 and FUAM-076915).

tiempo de juego, etc [7]. A la hora de modelar el comportamiento del usuario, se han utilizado diferentes enfoques basados especialmente en la minería de datos [4]. Debido a que este proceso de extracción es inicialmente ciego, es interesante considerar las técnicas no supervisadas dentro de la minería de datos, tales como el clustering [1], con el fin de hacer frente a este problema.

Este trabajo es un resumen de un trabajo previamente presentado en [6], que se centra en la aplicación de técnicas de clustering de series temporales [5] para la extracción de perfiles de usuario, basada no sólo en el comportamiento general, sino también en su evolución (ya que la evolución del jugador también debe tenerse en cuenta en el proceso de definición del perfil). Un videojuego completo, llamado “Dream”, ha sido creado con el fin de extraer los perfiles de usuario y su evolución. Este juego ha sido probado con algunos jugadores durante diferentes partidas de cara a afrontar estos objetivos.

2. La Arquitectura Analítica del Videojuego

La arquitectura del juego se divide en cuatro módulos:

- **Módulo del Juego:** Donde se realiza la partida. Dream está basado en el género Acción-RPG en primera persona. El jugador debe vencer a enemigos claves para avanzar en el juego. Se compone de: 4 fases con enemigos, un tutorial y un área de descanso. En cada fase los enemigos tienen distinta IA para obligar a los usuarios a modificar su estrategia. La Figura 1 muestra el entorno y el mapa del juego.
- **Módulo de extracción de datos:** Este módulo toma datos síncronos y asíncronos de los usuarios y los almacena en una base de datos de un servidor externo.
- **Módulo de generación del perfil básico:** Este módulo genera los perfiles básicos de los usuarios a través de las métricas definidas en la Sección 2.1.
- **Módulo de Análisis de Evolución de Perfiles:** Este módulo utiliza clustering de series temporales para extraer los perfiles de los usuarios de acuerdo a su evolución.

2.1. Métricas del Perfil

Las métricas utilizadas para generar los perfiles son:

- **“Fuerza”:** Esta métrica indica si un jugador (**pl**) tiene un perfil agresivo. Mide quien prefiere los ataques físicos (**PA**), aumenta atributos como fuerza (**SA**) y agilidad (**AA**) en lugar de otros atributos (**tot(A)**). Considera, además, el número de enemigos que el jugador ha matado (**EK**) sobre el total de los enemigos (**ET**) y el nivel alcanzado por el jugador (**LP**). El valor es:

$$st_{pl} = \frac{1}{4} \left(\frac{EK_{pl}}{ET} + \frac{SA_{pl} + AA_{pl}}{tot(A)_{pl}} + \frac{max(PA_{pl})}{max(PA_{all(pl)})} + \frac{max(LP_{pl})}{max(LP_{all(pl)})} \right). \quad (1)$$




Figura 1: Ejemplo del entorno durante una partida del juego “Dream”. Mapa completo de Dream dividido por regiones (derecha).

- **“Agilidad”**: favorece a quien resuelve cada fase diferente en el menor tiempo posible ($PT(i)$), comparado con los tiempos del resto de jugadores ($all(pl)$). También considera el número de enemigos asesinados (EK) para completar cada fase. El valor es:

$$ag_{pl} = \frac{1}{2} \left(\sum_{i=1}^4 \frac{PT(i)_{pl}}{\max(PT(i)_{all(pl)})} + \frac{1}{EK_{pl}} \right). \quad (2)$$

- **“Objetos”**: se basa en la adquisición ($ac()$) y el uso ($use()$) de los objetos. El uso y la adquisición de pociones (PO) y equipo (EQ) incrementará su valor:

$$it_{pl} = \frac{1}{4} \left(\frac{ac(PO)_{pl}}{tot(PO)} + \frac{ac(EQ)_{pl}}{tot(EQ)} + \frac{use(PO)_{pl}}{ac(PO)_{pl}} + \frac{use(EQ)_{pl}}{ac(EQ)_{pl}} \right). \quad (3)$$

- **“Defensa”**: indica quien incrementa atributos que aumentan la resistencia (RA) sobre otros atributos ($tot(A)$). También considera el mínimo golpe ($min(H)$) dado por un enemigo. Finalmente, el número total de muertes que el jugador sufre (DE) y los enemigos muertos (EK). El valor es:

$$df_{pl} = \frac{1}{4} \left(\frac{1}{EK_{pl}} + \frac{RA_{pl}}{tot(A)_{pl}} + \frac{1}{min(H)_{pl}} + \frac{1}{1 + DE_{pl}} \right). \quad (4)$$

- **“Inteligencia”**: muestra el uso de habilidades mágicas (MS), y si se aumenta de nivel (PL) matando el número mínimo posible de enemigos (EK/PL). También quién aumenta las habilidades mágicas MA sobre otros atributos ($tot(A)$). El valor de esta métrica es:

$$in_{pl} = \frac{1}{3} \left(\frac{MS_{pl}}{\max(MS_{all(pl)})} + \frac{MA_{pl}}{tot(A)_{pl}} + \frac{(EK/PL)_{pl}}{\max(EK/PL)_{all(pl)}} \right). \quad (5)$$




Figura 2: Perfil global de los usuarios basado en las cinco métricas. Estos resultados representan los usuarios más relevantes del proceso de extracción de perfiles.

3. Parámetros Experimentales

Para los experimentos se ha trabajado con unos 30 usuarios. Estos usuarios han jugado a Dream durante varias partidas (entre 3 y 17, dependiendo del usuario).

Los algoritmos que se han utilizado para el análisis son una combinación de algoritmos de clustering de series temporales [5] y el algoritmo de clustering Partition Around Medoids (PAM) [3].

Una vez que las series temporales se agrupan, se genera una matriz de disimilitud entre los usuarios para la fase de la evolución del perfil de usuario, donde:

$$diss(p_i, p_j) = 1 - \frac{\sum_{C_q} \delta_{C_q}^i \cdot \delta_{C_q}^j}{M} \quad (6)$$

Donde M es el número de métricas consideradas, p_i, p_j son los jugadores que deben compararse, C_q representa los grupos posible por métrica, y $\delta_{C_q}^i$ es la delta Dirichlet definida por:

$$\delta_{C_q}^i = \begin{cases} 1 & \text{if } p_i \in C_q \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

El proceso de agrupación final también se lleva a cabo usando PAM.

La métrica utilizada por el proceso de agrupación de series temporales es la medida de disimilitud denominada Autocorrelation-based Dissimilarity [5]. El valor de p que muestra resultados más estables para la métrica es 0.075. Además, el número de clusters que devuelve soluciones más estables, de acuerdo a la métrica de calidad de la suma de cuadrados [4], es 3.

4. Análisis de los Perfiles de Usuario

La aplicación de las técnicas de clustering de series temporales han extraído tres perfiles relevantes. Las Figuras 2 y 3 muestran los perfiles globales y los perfiles evolutivos, respectivamente. Estos resultados discriminan tres comportamientos:

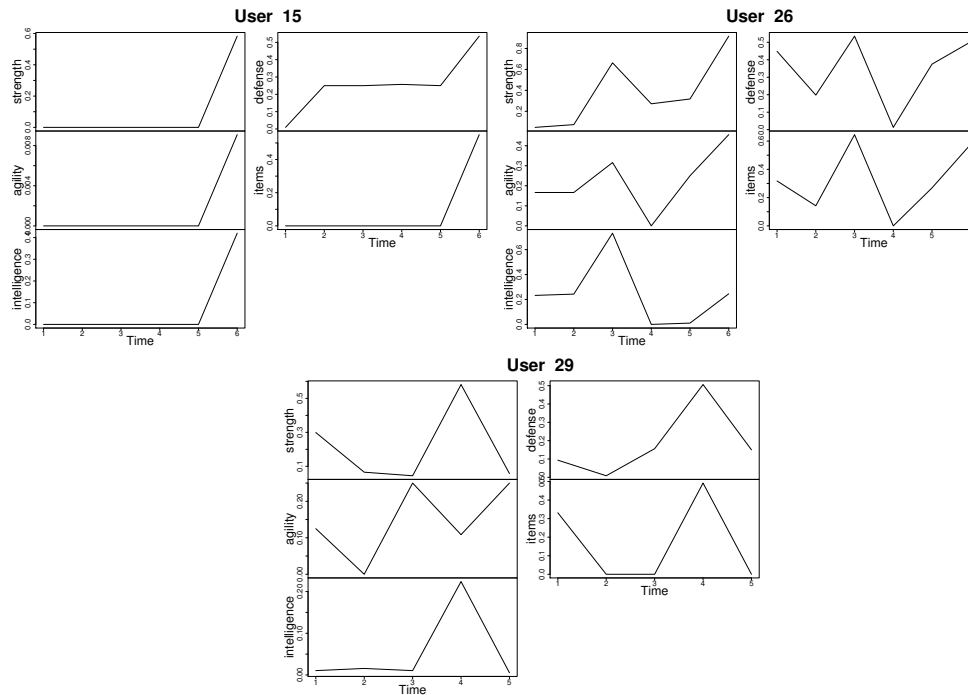


Figura 3: Evolución de cada usuario en los diferentes juegos que ha jugado. Estos resultados se utilizan por el proceso de clustering de series temporales.

- Perfil de Jugador Inexperto:** asociado con el usuario 15, cubre el 60% de los usuarios totales. Del perfil general los valores relacionados con la fuerza, objetos e inteligente son bajos, la agilidad es la más baja y su estrategia sólo se centra en la defensa. La evolución muestra que ha sido derrotado en varias ocasiones y sólo comienza a aprender después de varias partidas. Este tipo de jugador no se adapta profundamente al juego.
- Perfil de Jugador Medio:** asociado con el usuario 29, cubre el 20% de los usuarios totales. De forma general, tiene resultados bajos y balanceados según todas las métricas, excepto para la inteligencia. De acuerdo a su evolución, hay algunas tendencias que indica que están tratando de mejorar una métrica por partida, especialmente la defensa, la agilidad y los objetos usados.
- Perfil de Jugador Experimentado:** asociado con el usuario 26, cubre el 20% de los usuarios totales. Muestra buenas estadísticas generales. Consiguen adaptarse rápidamente al entorno de juego y tienen una experiencia de juego profunda. Su evolución es difusa ya que la adaptación real se produce durante la primera o segunda partida. Centran su evolución en la fuerza y la agilidad, tratando de optimizar sus decisiones en el juego.

Con la información del perfil de los usuarios, somos capaces de elegir a aquellos usuarios que podrían estar más interesados en las diferentes extensiones y proponer diferentes opciones para cada perfil.

5. Conclusiones y Trabajo Futuro

En este trabajo se ha presentado una metodología de análisis a partir de un juego llamado “Dream”. Durante el desarrollo de la partida, el jugador tiene que derrotar a sus enemigos usando diferentes habilidades y objetos con el fin de ayudarlo a completar cada fase. El juego extrae los datos de cómo esta partida se va desarrollando permitiendo generar perfiles de usuario.

Con la información sobre los perfiles, también proponemos una metodología (basada en el clustering de series temporales) para analizar la evolución del perfil del usuario durante la experiencia de juego, con el fin de discriminar los jugadores de acuerdo a sus habilidades de aprendizaje. Con esta información podemos identificar tres perfiles principales: los jugadores inexpertos, jugadores medios y jugadores experimentados. Usando estos perfiles, se pueden ofrecer futuras extensiones del juego de forma personalizada, con el fin de mejorar la experiencia de juego de cada jugador.

El trabajo futuro se centrará en los juegos online y el análisis multi-jugador. Usando la evolución del perfil, deberíamos ser capaces de proponer jugadores para diferentes equipos con el fin de mejorar la experiencia multijugador y también analizar el equipo en su conjunto, a fin de proponer extensiones personalizadas a cada equipo .

Referencias

1. Gema Bello-Orgaz, Héctor D. Menéndez, and David Camacho. Adaptive k-means algorithm for overlapped graph clustering. *International Journal of Neural Systems*, 22(05):1250018, 2012. PMID: 22916718.
2. Barry Ip. Technological, content, and market convergence in the games industry. *Games and Culture*, 3(2):199–224, 2008.
3. L. Kaufman and P. Rousseeuw. *Clustering by Means of Medoids*. Reports of the Faculty of Mathematics and Informatics. Faculty of Mathematics and Informatics, 1987.
4. Daniel T. Larose. *Discovering Knowledge in Data*. John Wiley & Sons, 2005.
5. T. Warren Liao. Clustering of time series data—a survey. *Pattern Recognition*, 38(11):1857 – 1874, 2005.
6. Héctor Menendez, Rafael Vindel, and David Camacho. Combining time series and clustering to extract gamer profile evolution. In *In Proceedings of the 6th International Conference on Computational Collective Intelligence Technologies and Applications*, (ICCCI 2014). Submitted., Seoul, Korea, 24th-26th September 2014.
7. Dmitri Williams, Nick Yee, and Scott E Caplan. Who plays, how much, and why? debunking the stereotypical gamer profile. *Journal of Computer-Mediated Communication*, 13(4):993–1018, 2008.