



Hacia un sistema recomendador de elementos de gamificación basado en el diseño centrado en el usuario

Toward a recommender system for gamification element based on user-centered design

Cristina Díaz Esquivel ✉

Universidad Autónoma de Aguascalientes, Aguascalientes, México
cristinaesquivel959@gmail.com
ORCID: 0009-0003-6990-5326

Luis Roberto Ramos Aguiar

Universidad Autónoma de Aguascalientes, Aguascalientes, México
roberto.ramos@edu.uaa.mx
ORCID: 0000-0002-1629-8310

Francisco Javier Álvarez Rodríguez

Universidad Autónoma de Aguascalientes, Aguascalientes, México
fjalvar.uaa@gmail.com
ORCID: 0000-0001-6608-046X

Perla Aguilar Navarrete

Universidad Autónoma de Nayarit, Tepic, Nayarit, México
paguilar@uan.edu.mx
ORCID: 0009-0001-9271-8102

Luis David Jiménez Martínez

Universidad Autónoma de Aguascalientes, Aguascalientes, México
al221273@edu.uaa.mx
ORCID: 0009-0002-4950-5176



<https://doi.org/10.36825/RITI.14.35.006>

Recibido: Junio 14, 2026

Aceptado: Octubre 02, 2026

Resumen: El uso de la gamificación ha incrementado significativamente en los últimos años, pero suele utilizarse de manera general, no todos los usuarios son iguales y los elementos de la gamificación no se pueden utilizar arbitrariamente, primero se deben conocer las preferencias del usuario para poder escoger los elementos de gamificación que mejor se adapten a él y así lograr mejores resultados. Por lo cual, se propone una prueba de concepto de un sistema recomendador de elementos de gamificación basado en el Diseño Centrado en el Usuario, utilizando Filtrado Basado en reglas y Aprendizaje por Refuerzo mediante el problema Bandido Multibrazo Contextual que, a diferencia del Bandido multibrazo tradicional, trabaja específicamente con el perfil de jugador

de cada usuario y la retroalimentación como contexto. Se presenta un estudio de viabilidad preliminar del sistema utilizando una hoja de cálculo y, para su evaluación, se utilizaron métricas de exactitud de predicción, ranking, error predictivo, diversidad y personalización. Los resultados de la simulación demuestran que, tras un periodo inicial de exploración, el sistema logra converger a partir de la tercera iteración, disminuyendo significativamente el error predictivo y generando recomendaciones altamente personalizadas ($P = 0.91$), acordes a la evolución del perfil híbrido y las preferencias.

Palabras clave: *Sistema Recomendador, Gamificación, Perfil Híbrido, Filtrado Basado en Reglas, Bandido Multibrazo Contextual.*

Abstract: The use of gamification has increased significantly in recent years, it is typically applied in a generalized manner. Not all users are the same, and gamification elements cannot be used arbitrarily. First, user preferences must be identified to select the gamification elements that best suit each individual and thereby achieve better outcomes. Therefore, this investigation proposes a proof of concept for a gamification element recommender system based on User-Centered Design, using Rule-Based Filtering and Reinforcement Learning through the Contextual MultiArmed Bandit problem, which, unlike the traditional MultiArmed Bandit, specifically incorporates each user's player profile and feedback as contextual information. A preliminary feasibility study of the system is presented using a spreadsheet, and its evaluation was conducted using prediction accuracy, ranking, predictive error, diversity, and personalization metrics. The simulation results demonstrate that, after an initial exploration period, the system converges from the third iteration onward, significantly reducing predictive error and generating highly personalized recommendations ($P=0.91$) that are consistent with the evolution of the hybrid profile and user preferences.

Keywords: *Recommender System, Gamification, Hybrid Profile, Rule-Based Filtering, Contextual Multi-Armed Bandit.*

1. Introducción

“La gamificación es el uso de elementos del juego y técnicas de diseño de juegos en contextos fuera del juego” [1], cuyo objetivo principal es mejorar la experiencia y motivar el comportamiento del usuario. Sin embargo, en la práctica, estos elementos suelen aplicarse de manera uniforme y genérica sin considerar las diferencias individuales, lo que mitiga drásticamente su efectividad a largo plazo [2].

Para solventar esta limitación, la gamificación basada en el Diseño Centrado en el Usuario toma desde un inicio las características, necesidades y preferencias individuales del usuario para utilizar los elementos que realmente necesita, logrando cumplir con el objetivo principal de la gamificación [3].

Una forma para poder determinar las preferencias del usuario desde un inicio es identificar su perfil de jugador. Trabajos previos han demostrado gran efectividad al utilizar elementos de gamificación basados en el perfil dominante de jugador. Siendo el perfil dominante aquel con el que el usuario se siente más identificado [4]. Sin embargo, existen diferentes modelos que identifican el perfil de jugador.

Por ejemplo, la taxonomía de Bartle fue el primer modelo de clasificación de jugadores, se basa en el comportamiento, interacción y motivación del usuario al interactuar con el entorno o con otros jugadores. Los perfiles son: triunfadores, sociables, exploradores y asesinos [5].

Posteriormente, surgió el modelo Hexad, un modelo de clasificación de tipos de jugadores desarrollado por Andrzej Marczewski que permite identificar las orientaciones motivacionales del usuario. Su objetivo es ayudar a desarrollar diseños de gamificación orientados a las necesidades de los usuarios para aumentar la efectividad del sistema, lograron observar que los usuarios responden de manera diferente a los elementos que los motivan. A diferencia de otros enfoques que utilizan solo recompensas, el modelo Hexad señala seis orientaciones motivacionales y cada uno tiene diferentes razones para interactuar con el sistema [6]:

El perfil filántropo es motivado por el propósito y la ayuda a los demás sin esperar algo a cambio. El perfil socializador muestra interés por la interacción social y la relación que tiene con otros jugadores. El perfil espíritu libre lo motiva la independencia y la exploración. El perfil triunfador es motivado por la competencia y superación. El perfil jugador se interesa por los premios y recompensas. El perfil disruptor muestra motivación por realizar cambios en el sistema [7].

Este modelo está especialmente relacionado con el perfil híbrido, en [6] se menciona que el 47% de los usuarios presentan combinaciones de diferentes perfiles, lo que impide clasificarse dentro de un perfil dominante.

El modelo Octalysis es un modelo de diseño conductual para la gamificación propuesto por Yu-Kai Chou, tiene como objetivo incrementar la motivación y la retención mediante la gamificación, la psicología y el comportamiento del usuario. Utiliza *Core Drivers*, fuerzas psicológicas que impulsan el comportamiento del jugador [8]. Asimismo, trata de entender los impulsos que provocan las acciones del usuario para así, lograr mejorar el diseño de experiencia de usuario [8], [9], cuenta con ocho perfiles diferentes:

El primer perfil es el significado épico y propósito, los usuarios piensan que son los elegidos para cumplir una misión importante. El segundo perfil es desarrollo y logro, quieren competir y mejorar sus habilidades para superar retos. El tercero representa el empoderamiento de creatividad, les gusta crear y recibir retroalimentación inmediata. El cuarto es la propiedad y posesión, intentan tener y controlar las cosas que les corresponden. El quinto perfil es la influencia social, les motiva la interacción social. El sexto es la escasez e impaciencia, para ellos es más atractivo lo raro o difícil de obtener. El séptimo perfil los representa la imprevisibilidad y curiosidad, continúan para saber lo que sigue después. El octavo corresponde a la evitación de pérdida, actúan para impedir perder algo importante [8], [9].

Todos los usuarios tienen un “perfil híbrido”, significa que todos se asocian con diferentes perfiles de jugador al mismo tiempo con diferentes niveles de impacto [10]. Es importante mencionar que un usuario, aunque comparta preferencias con otros, es diferente a todos los demás. Por ello, es de gran importancia conocer las características y preferencias individuales del usuario para aplicar los elementos de gamificación que realmente necesita. Es importante mencionar que estos perfiles evolucionan o cambian a lo largo del tiempo o contexto, por lo que se deben tomar las medidas necesarias para llevar el control correcto del cambio o evolución de las preferencias del usuario [6], una forma de llevar ese control es utilizando la fórmula de olvido.

La fórmula de olvido reduce el impacto que tienen los elementos con los que se interactuó en el pasado y da mayor peso a las preferencias actuales del usuario para realizar una mejor adaptación [11]. Para lograr la adaptación existen diferentes métodos, entre los cuales destaca el aprendizaje por refuerzo. Sin embargo, para su implementación es necesario delimitar su aplicación. Dentro de este contexto surge el sistema de recomendación como el núcleo principal de esta investigación.

Un sistema de recomendación es una rama de la inteligencia artificial que analiza información para filtrar, predecir y sugerir elementos que ser de interés para el usuario [12], [13]. Existen diferentes métodos para construir un sistema de recomendación, de los cuales este proyecto se centrará en el Filtrado basado en reglas y el aprendizaje por refuerzo aplicado al problema del bandido multibrazo contextual.

El filtrado basado en reglas es un enfoque dentro de los sistemas recomendadores que, a diferencia de los otros métodos, no piensa o aprende, lo único que hace es aplicar reglas definidas por el programador. Siguen la estructura de programación lógica IF-THEN, como entrada se utiliza la información del usuario. Después, el sistema verifica si se cumple con la condición de cada una de las reglas, guardando la información que se va generando al cumplirlas, dando como resultado o salida, la recomendación. Este método es de gran ayuda para comenzar, ya que se resuelve el arranque en frío al solo seguir las reglas que se definen con las características del usuario, sin necesitar una base de datos grande [14].

El aprendizaje por refuerzo es una de las ramas de la inteligencia artificial que se caracteriza por su aprendizaje mediante prueba y error. El agente interactúa con el entorno, que viene siendo el espacio de búsqueda y, mediante la toma decisiones, se le otorga recompensas al acertar o se penaliza al cometer un error para guiar su aprendizaje. Esto le ayuda a corregir su comportamiento incrementando su adaptación hasta llegar a maximizar el resultado [15]. El aprendizaje por refuerzo tiene muchas áreas de aplicación, pero pensando en que no se tiene información específica de otros usuarios que sea de ayuda para encontrar patrones y que solo podemos utilizar la retroalimentación dada por el usuario indicando sus preferencias, se aplicará al problema del bandido multibrazo contextual.

El problema del bandido multibrazo es comúnmente abordado por la teoría de la probabilidad y el aprendizaje por refuerzo. Está inspirado en un bandido que entra a un casino y comienza a jugar con las máquinas tragamonedas, este tipo de máquinas tiene una palanca lateral. El bandido debe tomar decisiones entre explorar y explotar las diferentes máquinas para obtener mayor recompensa [15]. Dentro de este problema, la exploración es moverse dentro del espacio de búsqueda hacia áreas de las que no se tiene información. En este caso, está presente al utilizar máquinas que no ha utilizado o que se ha usado poco para obtener más información [15];

mientras que la explotación se encuentra al enfocarse en un área donde se encontraron los mejores resultados para así, tratar de maximizar la solución. En este problema, se presenta al jalar la palanca de máquinas de las que se tiene información previa y que ha mostrado mayores ganancias. Es de gran importancia encontrar el balance entre la exploración y explotación, ya que, si alguna de estas dos se excede, el resultado puede quedar atrapado en un óptimo local o el resultado puede ser muy aleatorio [15].

El bandido multibrazo contextual es una evolución del bandido multibrazo original, ya que toma como contexto variables o información de su entorno. En cada iteración, el bandido guarda información importante que le ayuda a conocer características del usuario y tomar mejores decisiones. Como consecuencia, este tipo de bandido logra adaptarse al usuario de manera precisa [16]. Para comunicar al usuario con el sistema recomendador se puede utilizar una escala que indique lo que le gusta o no.

La escala Likert es una herramienta que ayuda a medir la preferencia que tiene el usuario ante determinada circunstancia, se le conoce como actitud [17]. Se aplica mediante enunciados de situaciones reales o teóricas y el usuario indica que tan identificado o de acuerdo está seleccionando una opción, ésta puede variar según las necesidades de quien la utiliza. La escala de 7, a diferencia de la escala de 5, suele apegarse más a la realidad del usuario, quiere decir que se obtienen resultados más precisos. Es importante mencionar que el diseño de la escala a utilizar debe ser definida desde la planeación del proyecto, ya que se deben tomar en cuenta los objetivos a alcanzar [17].

A pesar de los beneficios teóricos de este enfoque adaptativo, existe una brecha en la literatura actual, ya que la mayoría de los sistemas recomendadores existentes se limitan a perfiles fijos o recomiendan actividades previamente gamificadas, en lugar de iterar sobre los elementos específicos de gamificación en tiempo real.

Para abordar esta problemática, este artículo presenta una prueba de concepto y un estudio de viabilidad preliminar de un sistema recomendador adaptativo que unifica los modelos Hexad y Octalysis mediante un mecanismo de Bandidos Multibrazo Contextuales. El resto de este documento está organizado de la siguiente manera: la Sección 2 discute el trabajo relacionado; la Sección 3 detalla el modelo de arquitectura propuesto; la Sección 4 describe la metodología, el plan de evaluación y los resultados de la simulación; y finalmente, la Sección 5 expone las conclusiones y las líneas de trabajo futuro.

2. Estado del arte

El desarrollo de sistemas de recomendación en entornos interactivos ha cobrado un gran impulso en la última década. Para comprender el estado del arte y delimitar el alcance de la propuesta actual, en esta sección se analizan diversas investigaciones previas que convergen en la intersección de tres ejes fundamentales: los sistemas de recomendación, la gamificación adaptativa y el Diseño Centrado en el Usuario (DCU). El análisis de la literatura se estructuró a partir de cuatro dimensiones analíticas:

1. El modelo psicológico o taxonomía de usuario empleada (perfiles fijos vs. dinámicos/híbridos).
2. El mecanismo de captura de preferencias (interacción implícita vs. retroalimentación explícita).
3. El objeto de la recomendación (actividades completas ya gamificadas vs. elementos granulares de gamificación).
4. La estrategia algorítmica utilizada para resolver desafíos inherentes como el arranque en frío y el dilema de exploración-explotación.

En el estudio *Recommender Systems for Personalized Gamification* se propuso un modelo sobre el diseño de un sistema de recomendación para elementos de gamificación personalizada, se utilizan tres principales módulos. El primero es la entrada, donde se carga el perfil del usuario, los ítems a recomendar, la interacción del usuario con los ítems y el contexto. El segundo módulo es el proceso, aquí es donde se aplican los métodos o enfoques necesarios para el sistema recomendador. El último módulo es la salida, en este caso son los rankings predichos por el sistema. Se proponen cinco diferentes enfoques que pueden utilizarse: filtrado basado en contenido, filtrado colaborativo, recomendador sensible al contexto y recomendador híbrido. También se menciona que para obtener el contexto de los usuarios se puede registrar la interacción que tienen con el sistema o que los usuarios califiquen directamente la actividad o elemento utilizando una escala [18].

ReGammed un sistema de recomendación de diseños de gamificación. Utiliza el perfil de jugador Hexad, la configuración de recomendación definida por el administrador (preferencia o sentido de logro) y los objetivos del sistema a crear. Para la definición del tipo de perfil de jugador, el usuario debe contestar un cuestionario. Utilizaron un sistema de recomendación basado en evidencia, este enfoque utiliza una base de datos que relaciona diseños de

gamificación con los perfiles Hexad. Con Javascript crearon un ejemplo utilizando cruce matricial, cargan los valores estadísticos de un estudio anterior que sirven como pesos, después encuentra el valor máximo estadístico para determinado usuario y regresa el diseño correspondiente a ese valor. Se menciona que para su evaluación se requieren usuarios que interactúen con el diseño de gamificación y en base a la interacción, el sistema deberá hacer predicciones en base a la interacción del usuario con el sistema [19].

En el estudio *A Fuzzy DEMATEL-Based User-Centric Design Evaluation of Gamified Recommender Systems* construyeron cuatro diferentes prototipos para aprender inglés. Para los prototipos utilizaron Javascript y, a lo que se menciona, un recomendador simple y repaso espaciado. También utilizaron los enfoques PBL (Puntos, insignias y tablas de clasificación), AOP (Reconocimiento, Objetivos y Progreso), AOS (Reconocimiento, objetivos y presión social) y ACT (Reconocimientos, competencia y presión de tiempo). El sistema toma las características y la interacción del usuario al realizar las actividades, revisa el avance, rendimiento académico y el comportamiento para identificar las mecánicas y recompensas que serían más efectivas para su aprendizaje. Demuestran que los elementos de gamificación provocan reacciones muy diferentes en cada usuario. Además, el aumento de eficiencia y motivación son el efecto de aplicar correctamente los elementos de gamificación específicos para ese usuario, para ello aconsejan que debe haber una base sólida sobre teorías psicológicas y motivacionales [20].

En el estudio *Gamified Learning Systems' Personalized Feedback Report Dashboards via Custom Machine Learning Algorithms and Recommendation Systems* presentan tres sistemas recomendadores para actividades anteriormente gamificadas, el primero es el filtrado colaborativo de las preferencias del usuario, utilizan similitud coseno y *k-means*, crean grupos que califican similar a los experimentos y se recomiendan las actividades que le gustaron a los otros usuarios del mismo grupo. El segundo enfoque es el filtrado colaborativo, utilizan puntuaciones estándar del tiempo y porcentaje que se obtiene al finalizar la actividad, entonces equilibran el nivel de habilidad del usuario con el nivel de dificultad. El tercero es el filtrado basado en contenido, utilizando similitud coseno comparan los atributos de las actividades con la calificación de los experimentos que el usuario ya otorgó, se identifican los experimentos similares y se realiza la recomendación. Un problema que presentaron fue el arranque en frío, al depender de la interacción de los usuarios no tenían los datos necesarios para comenzar con buenas recomendaciones [21].

En el trabajo *Validation of User Preferences and Effects of Personalized Gamification on Task Performance* realizaron una comparación de la gamificación genérica con la gamificación basada en las preferencias del usuario. El grupo de control tenía todos los elementos activados automáticamente, mientras que el segundo grupo, para conocer los elementos que preferían, se les dio una lista de elementos donde podían seleccionar aquellos que preferían para presentarlos en el sistema. Además, contestaron encuestas psicológicas para conocer el perfil que presentaban. No programaron ningún algoritmo, pero al tomar en cuenta las preferencias de los usuarios desde un inicio, obtuvieron mejores resultados que el grupo de control: la motivación aumentó y completaron más actividades, además, los usuarios disfrutaron tener una interfaz adaptada a sus preferencias [10].

Como se mostró anteriormente, muy pocos proyectos toman en cuenta las características y preferencias de los usuarios, lo que puede provocar poca efectividad de los elementos de la gamificación o incluso puede llegar a desmotivar o frustrar al usuario. Gran parte de los trabajos utilizan perfiles de jugador fijos, en este caso, se utilizarán perfiles de jugador híbridos que combinan el modelo Hexad y el modelo Octalysis, además se plantea el cambio dinámico de estos perfiles mediante la retroalimentación del usuario. Gran parte de los estudios utilizan la interacción del usuario con el sistema para adaptarse, en el caso de este proyecto, el usuario da retroalimentación calificando mediante una escala Linkert sobre cada uno de los elementos recomendados. También se observó que en estudios utilizan actividades que están anteriormente gamificadas, en este proyecto se recomiendan elementos. Además, en este proyecto se realizarán diversas iteraciones que serán de ayuda para medir el cambio y la adaptación del sistema con el usuario.

3. Modelo propuesto

Con base en los hallazgos, se identificaron brechas y limitaciones en la revisión de la literatura, se diseñó una arquitectura de software orientada a resolver la rigidez de los sistemas de recomendación convencionales en gamificación. El modelo propuesto integra los principios del DCU con un enfoque híbrido de inteligencia artificial para garantizar una adaptación dinámica. La arquitectura conceptual del sistema y el flujo secuencial de interacciones se describen formalmente a continuación y se sintetizan visualmente en la Figura 1.




Figura 1. Modelo de Arquitectura.

3.1. Descripción de los Módulos de la Arquitectura del sistema recomendador

El diseño estructural del sistema está compuesto por cinco componentes interdependientes que interactúan de manera acoplada:

- **Módulo de Usuario.** Representa al usuario que interactúa con el sistema. Funciona como la fuente de datos primarios, capturando tanto los atributos demográficos y motivacionales iniciales como las respuestas conductuales posteriores en forma de retroalimentación para el sistema recomendador.
- **Módulo de Interfaz de usuario.** Es el que comunica al usuario con el sistema. Se encarga de definir el perfil de jugador del usuario, mostrar recomendaciones y enviar la retroalimentación al módulo de análisis.
- **Módulo del Modelo recomendador:** Se encarga de crear las recomendaciones, se utilizarán dos métodos diferentes: El primero es el filtrado basado en reglas. El segundo método es el problema del bandido multibrazo contextual, mediante la retroalimentación que el usuario realiza, el sistema aprende sobre los elementos específicos que funcionan para él.
- **Módulo de Análisis.** Procesa la nueva información y retroalimentación del usuario, actualiza los perfiles, compara las iteraciones y evalúa el modelo recomendador.
- **Módulo de la base de datos.** Almacena de manera estructurada los perfiles de los jugadores, los catálogos y matrices de elementos de gamificación, el histórico de las recomendaciones generadas, las trazas de retroalimentación por iteración y el registro acumulado de las métricas de desempeño.

A continuación, se describirán los dos métodos del modelo recomendador.

3.2. Métodos del modelo recomendador

El primer método es el filtrado basado en reglas, una herramienta que permite comenzar dando una recomendación que está orientada a las necesidades del usuario, ya que toma como entrada el perfil de jugador y, utilizando reglas lógicas definidas en la programación del modelo, se dará una primera recomendación. Con este método se resuelve

el problema del arranque en frío, ya que no se requiere de una interacción basada en el comportamiento del usuario para comenzar a adaptarse [13].

El segundo método es el problema del Bandido Multibrazo contextual, una forma de abordar el sistema recomendador. Simula un bandido que juega con diferentes máquinas tragamonedas, cada máquina devuelve una recompensa [16]. El bandido debe aprender la combinación de máquinas que son los mejores para maximizar la recompensa tomando en cuenta el contexto del entorno en el que se encuentra.

3.3. Dinámica y Flujo del sistema recomendador

La operación del sistema sigue un proceso iterativo de optimización continua guiado por el comportamiento del usuario.

1. Fase de Inicialización y Arranque en Frío: Primero, el usuario tendrá que contestar enunciados para definir su perfil híbrido de jugador. El filtrado basado en reglas utiliza la información para generar la primera recomendación, la cual es mostrada al usuario mediante la interfaz.
2. Fase de Retroalimentación Explícita: El usuario deberá ingresar su retroalimentación calificando cada elemento recomendado con la escala de Likert del 1 al 7. La retroalimentación pasa al módulo de análisis y la base de datos actualiza el perfil híbrido junto a la nueva información obtenida sobre sus preferencias. Por último, se calculan métricas que se describirán más adelante.
3. Fase de Retroalimentación Explícita: El usuario deberá ingresar su retroalimentación calificando cada elemento recomendado con la escala de Likert del 1 al 7. La retroalimentación pasa al módulo de análisis y la base de datos actualiza el perfil híbrido junto a la nueva información obtenida sobre sus preferencias. Por último, se calculan métricas que se describirán más adelante.

4. Metodología y Plan de Evaluación

Para validar la viabilidad técnica y el comportamiento adaptativo del sistema recomendador propuesto, el proceso de desarrollo y experimentación se estructuró bajo una metodología sistemática orientada en la ingeniería de software. El flujo de trabajo se dividió en cinco fases secuenciales:

1. Análisis: Delimitación de los requisitos funcionales y especificación del sistema mediante lenguajes de modelado unificado.
2. Diseño: Estructuración de la base de datos, mapeo de los perfiles de gamificación y mapeo de bandido multibrazo contextual.
3. Implementación: Programación y normalización matemática de la lógica del sistema recomendador híbrido para la simulación de escenarios controlados.
4. Evaluación: Selección y modelado matemático de las métricas de precisión, ranking, cobertura y personalización.
5. Resultados: Análisis del comportamiento y convergencia del algoritmo ante usuarios simulados.

A continuación, se describen con detalle las actividades realizadas en cada una de estas etapas.

4.1. Análisis

En la etapa de análisis se investigó sobre el tema para identificar las necesidades y limitaciones actuales. Se obtuvieron los requerimientos, en base a lo anterior se crearon diagramas de caso de uso, diagramas de flujo, diagramas de actividades y diagramas de clases.

4.2. Diseño

En la etapa de diseño se construyó el modelo de arquitectura, se obtuvo información para el diseño de la base de datos, se realizó la primera versión de las reglas para el primer método, además de un primer mapeo del problema del bandido multibrazo contextual. También se comenzó con el diseño de interfaz de usuario.

La primera parte es la definición del perfil de jugador, el modelo Hexad tiene seis perfiles y el modelo Octalysis tiene ocho. Entonces, el perfil híbrido que se utilizará en este proyecto tendrá un total de catorce perfiles

diferentes. Aunque ambos modelos tienen similitudes, es importante recordar que los dos modelos tienen diferente propósito sobre el usuario.

En la base de datos se guardará la información del usuario, como sus datos demográficos y su perfil híbrido, estarán los elementos de gamificación y su relación con los perfiles de los dos modelos anteriormente mencionados, también se registrarán las recomendaciones junto con la retroalimentación y diferentes métricas que comparan cada iteración o evalúan el sistema recomendador.

Siguiendo la metáfora del Bandido Multibrazo Contextual se realizó el mapeo inicial de sus principales elementos: El bandido es el motor recomendador que se adaptará al usuario; el perfil híbrido y la retroalimentación del usuario será el contexto que el bandido utilizará para generar la nueva recomendación; las máquinas tragamonedas representan los diferentes elementos de gamificación, los cuales, el bandido deberá elegir los cinco que calcule que tendrán mayor recompensa; la recompensa funciona con relación a la calificación que el usuario asigna a cada elemento recomendado.

Para esta etapa del proyecto, la implementación se enfoca solo en el primer método: Filtrado basado en reglas.

4.3. Implementación

Para obtener del perfil híbrido, se les muestra a los usuarios una serie de enunciados a los que debe asignar puntuaciones según el nivel con el que se identifica, se utiliza la escala *Likert* del 1 al 7. Es necesario normalizar el resultado utilizando la ecuación (1), cada enunciado corresponde a un perfil específico.

$$\text{porcentaje_perfil} = \left(\frac{\text{total_puntos}}{7} \right) * 100, \quad (1)$$

donde *total_puntos* es la sumatoria correspondiente a los puntos de los enunciados correspondientes a un perfil.

En hojas de cálculo se realizó una simulación de diferentes perfiles híbridos de jugador con el propósito de hacer una primera verificación de las reglas propuestas, del funcionamiento del proceso y confirmar que las métricas sirvan para nuestro propósito. Para la simulación, se definieron anteriormente las reglas para las recomendaciones, se agregó la retroalimentación para cada recomendación y se realizaron tres iteraciones.

Las reglas fueron clasificadas en tres grupos: dominancia, es de gran ayuda para identificar el perfil dominante del usuario y tomar en cuenta sus preferencias principales; individuales, se encargan de evaluar de manera independiente cada perfil para poder identificar si hay preferencia por alguno que aún no se tiene completamente identificado y así considerar sus preferencias individuales; por último, las reglas combinadas, este tipo combina al menos dos perfiles para lograr identificar patrones y recomendar elementos de diferentes motivaciones.

Primero se realiza una verificación para confirmar que, en cada modelo, la suma de sus perfiles correspondientes es igual a 100%, además, ningún perfil debe tener un porcentaje mayor a 100. Si una de estas dos verificaciones falla entonces, no se genera la recomendación. Después se inicializa una matriz donde a todos los elementos se les asigna una puntuación igual a cero.

Después, comienza la aplicación de las dos reglas de dominancia, donde se obtiene el perfil dominante de cada modelo para sumar un punto a los elementos de gamificación que están relacionados con ellos.

Posteriormente, se aplican nueve reglas individuales que utilizan el operador lógico OR. La cantidad de puntos fue asignada mediante la afinidad que hay entre el elemento y el perfil [6], [8], los porcentajes fueron asignados tomando en cuenta que cada perfil del modelo Hexad representa un 16.6%, mientras que cada perfil del modelo Octalysis representa un 12.5%:

- IF Triunfador $\geq 25\%$ o Logro $\geq 20\%$ entonces, sumar tres puntos a retos y niveles, además de sumar dos puntos a insignias, barra de progreso y misiones.
- IF Jugador $\geq 25\%$ o Propiedad $\geq 20\%$ entonces, sumar tres puntos a puntos y recompensas, también sumar dos puntos a coleccionables, insignias y desbloqueables.
- IF Social $\geq 25\%$ o Influencia social $\geq 20\%$ entonces, sumar tres puntos a equipos y retos grupales, asimismo sumar dos puntos a ranking, ayuda a otros e interacción social.

A continuación, se utilizan las nueve reglas combinadas, las cuales aplican el operador lógico AND. Empleando la misma lógica, estas reglas tratan de encontrar las diferentes motivaciones que tiene el usuario además de la dominante:

- IF Espíritu libre $\geq 20\%$ y Empoderamiento $\geq 15\%$ y Impresivilidad $\geq 12\%$ entonces, sumar 3 puntos a exploración libre y dos puntos a personalización, sorpresas y desbloqueables.
- IF Filántropo $\geq 20\%$ y Sentido épico $\geq 15\%$ e Influencia social $\geq 14\%$ entonces, sumar tres puntos a ayuda a otros y misiones con propósito, también sumar dos puntos a misiones colaborativas, reconocimiento social y narrativa.
- IF Espíritu libre $\geq 18\%$ y Disruptor $\geq 18\%$ y Empoderamiento $\geq 15\%$ entonces, sumar tres puntos a exploración libre, rutas alternativas y sumar dos puntos a personalización y modificar las reglas.

A partir de este momento, cada elemento suma los puntos obtenidos y se ordenan de mayor a menor, en casos de empate se revisa la afinidad. Para añadir diversidad, solo se toman máximo dos elementos de la misma familia, si existe un tercer elemento que pertenezca a la misma familia, lo omite y se toma el siguiente elemento. Si no se llega a completar la selección de cinco elementos entonces, se regresa al inicio de la lista para seleccionar los elementos faltantes ignorando la restricción.

4.4. Evaluación

La métrica Ganancia Acumulada Descontada Normalizada (NDCG por sus siglas en inglés), definida en la ecuación (2), evalúa que tan relevantes son los elementos recomendados y su posición en la lista, ayuda a asegurar que el mejor aparezca primero [22], [23].

$$NDCG = \frac{DCG}{IDCG}, \quad (2)$$

donde DCG es la ganancia acumulada descontada, se calcula sumando la relevancia de cada elemento y reduciendo el valor por su posición. $IDCG$ es la ganancia acumulada descontada ideal, se calcula sumando la relevancia los elementos, pero ordenados de manera descendente y reduciendo el valor por su posición.

La métrica Error cuadrático (RMSE por sus siglas en inglés), definida en la ecuación (3), evalúa la precisión de la predicción numérica, ayuda a que el sistema no haga recomendaciones muy alejadas de la realidad, se compara la predicción con el valor real [23].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - \hat{r}_i)^2} \quad (3)$$

donde n es el tamaño de la muestra, r_i es el valor real dado por el usuario, $\hat{r}_i$ representa el valor predicho por el sistema.

La métrica área bajo la curva ROC (AUC-ROC), definida en la ecuación (4), evalúa si el sistema sabe clasificar entre los elementos que son relevantes y los que no [22], [23].

$$AUC = \frac{\sum R_i - \frac{n_p(n_p + 1)}{2}}{n_p \times n_n} \quad (4)$$

donde n_p son los casos positivos reales, n_n son los casos negativos reales, R_i representa la suma de los rangos de los casos positivos. Cabe mencionar que el denominador representa el número total de pares posibles combinando cada elemento positivo con cada elemento negativo.

El *Item Coverage*, definida en la ecuación (5), mide el número de elementos diferentes que se están recomendando al usuario, se utiliza para verificar que no se recomiende lo mismo para los otros usuarios [23].

$$coverage = \frac{U_{u \in U} I(u)}{I} \quad (5)$$

donde U es el número total de usuarios, u representa un usuario, I representa el listado completo de ítems.

La personalización o unicidad, definida en la ecuación (6), se utiliza para ver qué tan diferentes son las listas de recomendaciones entre dos diferentes usuarios para verificar que el sistema recomendador entienda que todos son diferentes.

$$P = 1 - \frac{1}{N(N-1)} \sum sim(L_u, L_v) \quad (6)$$

donde N es el número de usuarios, L_u y L_v son las recomendaciones generadas, entonces $sim(L_u, L_v)$ representa la similitud entre dos usuarios.

4.5. Resultados

Para la simulación se realizaron 3 iteraciones con dos usuarios y 35 elementos de gamificación. A continuación, la Tabla 1 y la Tabla 2 muestran el cambio en los porcentajes del perfil híbrido tras realizar la retroalimentación de los elementos de gamificación recomendados. Posteriormente, se muestra la Tabla 3 muestra los resultados obtenidos de las métricas:

Tabla 1. Perfil de jugador 1 por iteraciones.

Perfil usuario 1	Iteración 1	Iteración 2	Iteración 3
Triunfador	0.4	0.1	0.08
Social	0.1	0.35	0.42
Espíritu libre	0.25	0.1	0.06
Filántropo	0.1	0.25	0.32
Player	0.1	0.15	0.07
Disruptor	0.05	0.05	0.05
Sentido épico y propósito	0.1	0.1	0.15
Desarrollo y logro	0.35	0.1	0.05
Empoderamiento	0.2	0.1	0.05
Propiedad y posesión	0.1	0.15	0.12
Influencia social	0.1	0.3	0.4
Escasez e impaciencia	0.05	0.05	0.03
Imprevisibilidad y curiosidad	0.05	0.05	0.03
Evitación de pérdida	0.05	0.15	0.17

Fuente: Elaboración propia.

Tabla 2. Perfil de jugador 2 por iteraciones.

Perfil usuario 2	Iteración 1	Iteración 2	Iteración 3
Triunfador	0.1	0.07	0.05
Social	0.35	0.42	0.45
Espíritu libre	0.1	0.08	0.07
Filántropo	0.25	0.33	0.36
Player	0.15	0.06	0.04
Disruptor	0.05	0.04	0.03
Sentido épico y propósito	0.1	0.14	0.16
Desarrollo y logro	0.1	0.05	0.03
Empoderamiento	0.1	0.08	0.06
Propiedad y posesión	0.15	0.12	0.1
Influencia social	0.3	0.42	0.46

Escasez e impaciencia	0.05	0.03	0.02
Imprevisibilidad y curiosidad	0.05	0.03	0.02
Evitación de pérdida	0.15	0.13	0.15

Fuente: Elaboración propia.

Al inicio, el usuario 1 comienza siendo competitivo y orientado a logros, se interesa por las recompensas y el progreso. Pero después, comienza a mostrar interés por la interacción social, la narrativa y la exploración. El sistema observa que el usuario responde mejor a los elementos sociales, así que reajusta sus pesos y realiza una nueva recomendación tomando en cuenta los elementos relacionados a este perfil. Del mismo modo se puede observar que, en el perfil Disruptor, el porcentaje se mantiene igual porque el sistema no ha encontrado evidencia significativa para modificarlo. El segundo usuario mantiene su interés por lo social, al correr las iteraciones, el sistema aprende que la competencia no lo motiva y que muestra mayor interés en la narrativa, aumentando el porcentaje al perfil Filántropo.

Tabla 3. Resultados de evaluación.

Usuario	Iteración	RMSE	NDCG	AUC_ROC
1	1	2.69	0.82	0.79
1	2	3.91	0.55	0.73
1	3	0.54	0.97	0.92
2	1	3.84	0.51	0.72
2	2	0.83	0.93	0.89
2	3	0.09	0.99	0.98

Fuente: Elaboración propia.

En el caso del primer usuario, la métrica del Error cuadrático (RMSE) se puede observar que el valor aumentó si comparamos las primeras dos iteraciones, esto es muy común en las primeras iteraciones por la fase de la exploración en el espacio de búsqueda. En la tercera iteración se aprecia una gran mejora disminuyendo su valor de 3.91 a 0.54. En el caso del usuario 2, el sistema comenzó tendiendo un error muy grande, lo que quiere decir que fue una recomendación muy poco precisa, pero en la tercera iteración, el sistema logró mejorar significativamente disminuyendo su valor al 0.09, que es muy cercano a 0.

En cuanto al orden de los elementos de la recomendación, validada por la métrica NDCG, comparando las dos primeras iteraciones del usuario 1, se observa que tuvo un buen comienzo, pero empeora. Al realizar la tercera recomendación el resultado logra obtener un valor de 0.97. En el segundo usuario, la primera iteración tuvo un valor intermedio, a partir de la segunda iteración mejora significativamente hasta lograr un valor casi perfecto de 0.99, muy cercano al 1.

La curva ROC señala que, en la tercera iteración para ambos casos, el sistema logra diferenciar entre lo que si le interesa al usuario y lo que no. En la personalización se obtuvo un valor de 0.91, muy cercano a 1, comprobando que las recomendaciones generadas para ambos usuarios fueron muy diferentes. Esto se debe a la diferencia entre los dos perfiles, verificando que el sistema es capaz de adaptarse a las diferencias individuales.

Comparando a los dos usuarios, es notable que los perfiles del segundo se mantienen estables, mientras que el primero tiene cambios repentinos. Esta característica será importante para tener en cuenta al realizar las pruebas con usuarios reales.

En general, las primeras iteraciones muestran poca precisión, pero con la retroalimentación de cada iteración, el sistema logra converger y realizar recomendaciones precisas. Además, el uso de perfiles híbridos ayudó a alcanzar una mejor adaptación.

Una limitación dentro de este trabajo es la simulación con pocos usuarios y pocas iteraciones, por lo que estos resultados deben interpretarse como una prueba de concepto. Si bien, logramos una primera verificación sobre las reglas y las métricas, en la simulación se utilizan solo las reglas definidas anteriormente, sin tener aprendizaje por refuerzo, como lo hará el segundo método del sistema recomendador al utilizar el problema del bandido multibrazo contextual. Además, se tiene solo una simulación utilizando hojas de cálculo y no un prototipo funcional.

5. Conclusiones y trabajo futuro

En esta investigación se presentó un sistema recomendador de elementos de gamificación adaptativa basado en el diseño centrado en el usuario. La arquitectura propuesta integra perfiles híbridos enlazados a elementos de gamificación basándose en los perfiles de jugador: Hexad y Octalysis.

Los resultados de la simulación demostraron que, tras una fase inicial de exploración con margen de error elevado, el algoritmo logra converger hacia la tercera iteración. Esto se evidencia en una reducción drástica del error predictivo (RMSE alcanzando 0.54 y 0.09), un ordenamiento casi óptimo en la relevancia de los elementos recomendados (NDCG de 0.97 y 0.99) y una alta capacidad de discriminación entre preferencias (AUC-ROC de 0.92 y 0.98). Asimismo, el índice de personalización obtenido $P = 0.91$ confirma que la propuesta genera recomendaciones diferenciadas y adaptadas tanto a trayectorias de interacción estables como a cambios drásticos en el comportamiento del usuario.

A pesar de las limitaciones inherentes a una prueba de concepto ejecutada mediante entornos simulados y reglas lógicas, los hallazgos validan experimentalmente la arquitectura propuesta como un cimiento sólido para resolver el problema del arranque en frío y la adaptación continua.

Como trabajo futuro, se plantea la implementación del sistema recomendador utilizando el lenguaje Python, así como, la integración de la fórmula de fórmula de olvido para mejorar el cambio dinámico de los perfiles y la puntuación de los elementos. La evaluación continuará usando la misma metodología con usuarios reales y un mayor número de iteraciones. Adicionalmente, se planea incorporar en la interfaz un historial para que el usuario pueda consultar las recomendaciones y retroalimentaciones anteriores.

6. Agradecimientos

Expresamos nuestro profundo agradecimiento al Dr. Francisco Javier Álvarez Rodríguez, al Dr. Luis Roberto Ramos Aguiar y a la Dra. Perla Aguilar Navarrete por compartir su valioso conocimiento y por su apoyo brindado para el desarrollo de esta investigación.

7. Referencias

- [1] El Shoubashy, H., El Kader, H. A., Khalifa, N. (2020). What is Gamification? Literature Review of Previous Studies on Gamification. *Australian Journal of Basic and Applied Sciences*, 14 (8), 29–51. [https://www.ajbasweb.com/old/ajbas/2020/August/29-51\(4\).pdf](https://www.ajbasweb.com/old/ajbas/2020/August/29-51(4).pdf)
- [2] Øvensen, E., Scholz, T. M., Andersen, R., Prinz, A. (2025). *From game elements to meaningful motivation: a design-centred approach to gamification*. 18th Annual International Conference of Education, Research and Innovation, Seville, Spain. <https://doi.org/10.21125/iceri.2025.2150>
- [3] Cobarrubias Soto, N., Rodríguez López, H. (2022). Diseño centrado en el usuario: interacción hombre-computadora. *Revista Digital de Tecnologías Informáticas y Sistemas*, 6 (1), 78-84. <https://doi.org/10.61530/redtis.2022.6.6.124.7>
- [4] Martín-Rodríguez, I., Lomba Pérez, A., Ramos Montesdeoca, M. (2024). Identificación de perfiles de videojugadores para narrativas gamificadas: una revisión de alcance. *Cuestiones Pedagógicas*, 2 (33), 73–92. <https://doi.org/10.12795/cp.2024.i33.v2.04>
- [5] Torres-Toukoumidis, Á., Romero-Rodríguez, L. M., Salgado Guerrero, J. P. (2019). *Juegos y sociedad: desde la interacción a la inmersión para el cambio social* (1era. Ed.). McGraw Hill.
- [6] Marczewski, A. (2012). *HEXAD User Types Framework*. <https://hexad.gamified.uk/>
- [7] Tondello, G. F., Wehbe, R. R., Diamond, L., Busch, M., Marczewski, A., Nacke, L. E. (2016). *The gamification user types Hexad scale*. Annual Symposium on Computer-Human Interaction in Play, Austin, Texas, USA. <https://doi.org/10.1145/2967934.2968082>
- [8] The Octalysis Group. (n.d.). *Framework - The Octalysis Framework for High-Performing Products*. <https://octalysisgroup.com/octalysis-framework/>
- [9] Teixes Argilés, F. (2017). Actionable Gamification: beyond points, badges and leaderboards. Octalysis Media: Fremont. CA. *Revista Internacional De Organizaciones*, (18), 137-144. <https://doi.org/10.17345/rio18.137-144>

- [10] Tondello, G. F., Nacke, L. E. (2020). Validation of User Preferences and Effects of Personalized Gamification on Task Performance. *Frontiers in Computer Science*, 2, 1-23. <https://doi.org/10.3389/fcomp.2020.00029>
- [11] Li, T., Jin, L., Wu, Z., Chen, Y. (2019). Combined recommendation algorithm based on improved similarity and forgetting curve. *Information*, 10 (4), 1-18. <https://doi.org/10.3390/info10040130>
- [12] Almaraz Pérez, A., Goddard Close, J. (2015). Sistemas de Recomendación. *Komputer Sapiens*, 7 (1), 12–15. <https://smia.mx/komputersapiens/publicaciones.php>
- [13] Bron Fonseca, B., Mar Cornelio, O. (2022). Sistemas de recomendación para la toma de decisiones. Estado del Arte. *UNESUM - Ciencias. Revista Científica Multidisciplinaria*, 6 (1), 149–164. <https://doi.org/10.47230/unesum-ciencias.v6.n1.2022.289>
- [14] Abel, F., Bittencourt, I. I., Henze, N., Krause, D., Vassileva, J. (2008). A Rule-Based Recommender System for Online Discussion Forums. En W. Nejdl, J. Kay, P. Pu, E. Herder (Eds), *Adaptive Hypermedia and Adaptive Web-Based Systems* (pp.12-21). Springer. https://doi.org/10.1007/978-3-540-70987-9_4
- [15] Guinea Juliá, Á. (2016). *Introducción al aprendizaje por refuerzo: problema bandido multibrazo* [Trabajo de Fin de Grado]. Universidad Autónoma de Madrid, España. <https://repositorio.uam.es/server/api/core/bitstreams/fc72fce0-9ecd-4961-8237-9d771e69f016/content>
- [16] Hernández Roldán, I., Magarzo Gonzalo, A. (2023). Bandidos Contextuales: Fundamentos y Aplicaciones [Trabajo de Fin de Grado]. Universidad Complutense de Madrid, España. <https://hdl.handle.net/20.500.14352/87700>
- [17] Joshi, A., Kale, S., Chandel, S., Pal, D. K. (2015). Likert Scale: Explored and Explained. *Current Journal of Applied Science & Technology*, 7 (4), 396–403. <https://doi.org/10.9734/bjast/2015/14975>
- [18] Tondello, G. F., Orji, R., Nacke, L. E. (2017). *Recommender systems for personalized gamification*. 25th Conference on User Modeling, Adaptation and Personalization (UMAP), Bratislava, Slovakia. <https://doi.org/10.1145/3099023.3099114>
- [19] Vasconcelos, G., Oliveira, W., Guimarães Santos, A. C., Hamari, J. (2022). *ReGammend: A method for personalized recommendation of gamification designs*. 6th International GamiFIN Conference, Finland. <https://ceur-ws.org/Vol-3147/paper9.pdf>
- [20] Başaran, S., Taqi, A. M. (2025). A Fuzzy DEMATEL-Based User-Centric Design Evaluation of Gamified Recommender Systems. *Applied Sciences*, 15 (21), 1-29. <https://doi.org/10.3390/app152111456>
- [21] Raftopoulou, N. M., Pallis, P. (2023). Gamified Learning Systems' Personalized Feedback Report Dashboards via Custom Machine Learning Algorithms and Recommendation Systems. *Sociology Study*, 13 (3), 161-173. <https://doi.org/10.17265/2159-5526/2023.03.006>
- [22] Manning, C. D., Raghavan, P., Schütze, H. (2009). *An Introduction to Information Retrieval*. Cambridge University Press. <https://nlp.stanford.edu/IR-book/pdf/irbookonlinereading.pdf>
- [23] Chen, M., Liu, P. (2017). Performance evaluation of recommender systems. *International Journal of Performability Engineering*, 13 (8), 1246–1256. <https://doi.org/10.23940/ijpe.17.08.p7.12461256>