



Pontificia Universidad  
**JAVERIANA**  
Cali

**Prototipo para recomendación de juegos de mesa para experiencias de  
aprendizaje basado en juegos**

Cristian Andrés Carabalí Lobo

Código 400061078

Director(a)

David Sebastian Baldeón Padilla

Codirector(a)

Juan Carlos Martínez Arias

**FACULTAD DE INGENIERÍA Y CIENCIAS  
INGENIERÍA DE SISTEMAS Y COMPUTACIÓN**

SANTIAGO DE CALI, FEBRERO 3 DE 2026

# TABLA DE CONTENIDOS

Lista de figuras.....	8
Abstract.....	9
Resumen.....	10
1. Introducción .....	11
1.1. Planteamiento del problema.....	11
1.1.1. Formulación del problema .....	12
1.1.2. Sistematización del problema .....	13
1.2. Objetivos.....	13
1.2.1. Objetivo general.....	13
1.2.2. Objetivos específicos .....	13
1.3. Justificación .....	14
1.3.1. Utilidad .....	14
1.3.2. Impacto .....	15
1.3.3. Viabilidad.....	15
1.4. Alcances y Limitaciones .....	16
2. Marco Teórico y Trabajos Relacionados .....	17
2.1. Marco de referencia .....	17
2.1.1. Marco teórico.....	17
2.1.1.1. Sistemas de recomendación [1] .....	17
2.1.1.2. Representación semántica con NLP.....	19
2.1.1.3. Aprendizaje basado en juegos y el uso de juegos de mesa en educación .....	21
2.1.1.4. Consideraciones para la selección y adaptación de juegos de mesa didácticos	

2.2.	Trabajos relacionados .....	28
2.2.1.	Sequential Recommendations on Board, Game Platforms [22] .....	28
2.2.2.	Personalized Online Learning Resource Recommendation Based on Artificial Intelligence.....	29
2.2.3.	Board Game Recommendation Engine , Quantic Foundry [24].....	30
2.2.4.	Hybrid System for Video Game Recommendation Based on Implicit Ratings and Social	30
2.2.5.	Building Recommendation Systems for Board Games [26].....	31
2.2.5.1.	Recommender System for Board Games Using Game Concepts [27] .....	32
3.	Metodología .....	34
3.1.	Enfoque de Prototipado Evolutivo.....	34
3.1.1.	¿En qué consiste? .....	34
3.1.2.	Principios fundamentales .....	34
3.1.3.	Fases típicas .....	34
3.1.4.	Ventajas y desventajas .....	35
3.1.5.	Cuándo usarlo .....	35
3.2.	Actividades planificadas .....	35
3.2.1.	Caracterizar el uso actual de los juegos de mesa en el CJEI en términos de objetivos de clase, habilidades promovidas y condiciones operativas de las sesiones (tiempo disponible, tamaño de grupo, dependencia de idioma, disponibilidad de juegos) .....	35
3.2.2.	Diseñar y documentar una taxonomía que relacione juegos de mesa, habilidades y objetivos de aprendizaje, a partir de la integración y normalización de metadatos provenientes de BoardGameGeek (BGG) y del catálogo del CJEI, incluyendo atributos como duración, dificultad, número de jugadores, mecánicas, dependencia de idioma, disponibilidad y posición en el ranking general de BGG. ....	36
3.2.3.	Especificar los requerimientos funcionales y no funcionales del prototipo de sistema de recomendación y de su herramienta web, incorporando criterios de trazabilidad de	

los criterios de selección, identidad visual acorde al CJEI y necesidades de uso por parte de los asesores pedagógicos.....	36
3.2.4. Desarrollar e implementar el prototipo del sistema de recomendación para la ludoteca del CJEI, combinando filtrado basado en contenido, reglas pedagógicas y retroalimentación de uso e incorporando el modelado de habilidades primarias y secundarias trabajadas por cada juego mediante análisis de texto (NLP) .....	37
4. Requerimientos del sistema .....	38
4.1. Requisitos funcionales (RF) especifican qué debe hacer el sistema: servicios, flujos de trabajo y reglas de negocio visibles para el usuario.....	38
4.1.1 Criterios de aceptación y dependencias (extracto del MVP) .....	41
4.2. Requisitos no funcionales (RNF) describen cómo debe comportarse el sistema: atributos de calidad (rendimiento, seguridad ergonomía etc) o restricciones tecnológicas y normativas.	42
5. Análisis y diseño .....	43
5.1. Visión del sistema y alcance funcional del prototipo .....	43
5.2. Actores, perfiles de usuario y contexto de uso .....	43
5.3. Casos de uso y flujos de interacción .....	44
5.4. Arquitectura lógica del prototipo .....	45
5.5. Modelo de información y fuentes de datos .....	45
5.6. Taxonomía pedagógica y representación de objetivos de aprendizaje .....	46
5.7. Diseño del motor de recomendación.....	47
5.8. Procesamiento semántico (NLP) y enriquecimiento de información .....	48
5.9. Diseño de explicabilidad y trazabilidad de recomendaciones .....	48
5.10. Diseño de la interfaz de usuario (UI/UX) .....	49
5.11. Reglas de negocio y validaciones .....	49
5.12. Trazabilidad Requerimientos - Diseño .....	50
6. IMPLEMENTACIÓN.....	51

6.1.	Alcance de la implementación y criterios de completitud del prototipo .....	51
6.2.	Entorno de desarrollo y dependencias del proyecto .....	52
6.2.1.	Comandos de referencia para levantar el prototipo en entorno local: .....	52
6.2.2.	URLs de acceso reportadas para el entorno local: .....	53
6.3.	Construcción de la base de datos y preparación de fuentes de información.....	53
6.4.	Implementación del modelo de información (persistencia).....	53
6.5.	Implementación del motor de recomendación .....	54
6.6.	Implementación de explicabilidad y trazabilidad .....	54
6.7.	Implementación de la interfaz de usuario (UI) .....	55
6.8.	Integración de componentes y flujo extremo a extremo .....	56
6.9.	Verificación técnica interna de la implementación.....	56
6.9.1.	Comandos de ejecución de pruebas backend reportados:.....	56
6.9.2.	Escenarios E2E reportados como validados: .....	57
7.	PLAN DE VALIDACIÓN Y RESULTADOS.....	58
7.1.	Plan de Validación .....	58
7.1.1.	Propósito y alcance de la validación.....	58
7.1.2.	Dimensiones de evaluación e indicadores (matriz de métricas) .....	59
7.1.3.	Participantes y contexto de validación.....	61
7.1.4.	Diseño de pruebas piloto y casos de uso.....	62
7.1.5.	Instrumentos y fuentes de evidencia .....	64
7.1.6.	Procedimiento de recolección (paso a paso).....	65
7.1.7.	Criterios de análisis y tratamiento de datos .....	66
7.1.8.	Consideraciones éticas, sesgos y limitaciones del piloto.....	67
7.2.	Resultados de las pruebas .....	67
7.2.1	Caracterización del piloto .....	67

7.2.2	Resultados por dimensión (alineado a OE5 y pregunta 5).....	68
7.2.2.1	Usabilidad (hallazgos, evidencia) .....	68
7.2.2.2	Utilidad percibida y aceptación por asesores (valoraciones, verbatim).....	68
7.2.2.3	Impacto en tiempos de preparación (resultados reportados).....	69
7.2.2.4	Consistencia de recomendaciones (resultados reportados).....	69
7.2.2.5	Preservación del conocimiento institucional (resultados reportados).....	69
7.2.2.6	Precisión, calidad técnica de la recomendación.....	70
7.2.3	Síntesis de hallazgos y ajustes derivados.....	70
7.3.	Evaluación de Rendimiento .....	71
7.3.1	Rendimiento del sistema (tiempos de respuesta y carga) .....	71
7.3.2	Rendimiento del procesamiento de datos y recomendación .....	72
7.3.3	Robustez y manejo de casos límite .....	72
8.	Discusión.....	74
8.1.	Selección del enfoque de recomendación: pertinencia del híbrido frente a alternativas 74	
8.2.	Reglas de negocio, filtros duros y coherencia con el enfoque usuario-centrista .....	75
8.3.	Explicabilidad, trazabilidad y preservación de conocimiento: aporte diferencial del prototipo.....	76
8.4.	Taxonomía pedagógica y selección de juegos: alineación con teorías del aprendizaje	76
8.5.	Aprendizaje basado en juegos, gamificación y juegos de mesa: evidencia, heterogeneidad y cautelas .....	77
8.6.	Procesamiento semántico (NLP) como capacidad incremental: pertinencia y prudencia 78	
8.7.	Evaluación del prototipo: discusión metodológica sobre métricas offline y evaluación con usuarios .....	78
8.8.	Limitaciones del enfoque y amenazas a la validez .....	79

9.	CONCLUSIONES .....	80
10.	Trabajo futuro .....	81
11.	Bibliografía .....	82
12.	Anexos .....	86

## Lista de tablas

Tabla 1 Resumen de requisitos funcionales por módulo (MoSCoW) .....	38
Tabla 2. Lista de requisitos funcionales (RF) .....	39
Tabla 3 Requisitos no funcionales (RNF) identificados y su verificación. ....	42
Tabla 4. <i>Casos de uso principales del prototipo</i> .....	44
Tabla 5. <i>Matriz de trazabilidad Requerimientos - Diseño (resumen)</i> .....	50
Tabla 6. Stack tecnológico .....	52
Tabla 7. Matriz de métricas .....	59
Tabla 8. Participantes .....	61
Tabla 9. Matriz de casos .....	62
Tabla 10 Matriz de instrumentos por dimensión: .....	65
Tabla 11 Matriz de casos límite propuesta: .....	72

## Abstract

Schools that use board games as a teaching resource often rely on the tacit knowledge of their advisors to select titles appropriate to a learning objective, session context, and operational constraints (time, group size, availability, and language dependency) This dependence hinders the transfer of accumulated experiences, increases variability in selection and can increase the preparation times of activities. In response, this paper develops a prototype board game recommendation system aimed at supporting game-based learning in the CJEI, with an emphasis on preserving institutional knowledge and offering justified recommendations.

The development was structured in phases of survey and specification of requirements, modeling of the catalog information, definition of a pedagogical taxonomy of skills and objectives, and construction of a hybrid recommendation engine that combines eligibility filters with a configurable scoring scheme. The prototype also incorporates explainability mechanisms to make the criteria used transparent (e.g., correspondence with ability, mechanics, and difficulty) and a feedback component that allows recording experiences of use to consolidate and reuse operational and pedagogical learning.

To evaluate its performance and relevance in the real context, a validation plan is defined focused on the efficiency of the preparation process, consistency of the recommendations, preservation of institutional knowledge, usability and usefulness perceived by advisors, as well as the technical quality of the recommendation. As a contribution, a reference solution is delivered that integrates pedagogical design, software architecture and decision traceability, enabling future iterations and extensions of the scope according to the needs of the CJEI.

**Keywords:** recommendation system; board games; game-based learning; explainability; knowledge preservation.

## Resumen

Los centros educativos que emplean juegos de mesa como recurso didáctico suelen depender del conocimiento tácito de sus asesores para seleccionar títulos adecuados a un objetivo de aprendizaje, a un contexto de sesión y a restricciones operativas (tiempo, tamaño de grupo, disponibilidad y dependencia de idioma). Esta dependencia dificulta la transferencia de experiencias acumuladas, incrementa la variabilidad en la selección y puede elevar los tiempos de preparación de las actividades. En respuesta, este trabajo desarrolla un prototipo de sistema de recomendación de juegos de mesa orientado a apoyar el aprendizaje basado en juegos en el CJEI, con énfasis en preservar conocimiento institucional y en ofrecer recomendaciones justificadas.

El desarrollo se estructuró en fases de levantamiento y especificación de requerimientos, modelado de la información del catálogo, definición de una taxonomía pedagógica de habilidades y objetivos, y construcción de un motor de recomendación híbrido que combina filtros de elegibilidad con un esquema de puntuación configurable. El prototipo incorpora además mecanismos de explicabilidad para transparentar los criterios utilizados (por ejemplo, correspondencia con habilidad, mecánicas y dificultad) y un componente de retroalimentación que permite registrar experiencias de uso para consolidar y reutilizar aprendizajes operativos y pedagógicos.

Para evaluar su desempeño y pertinencia en el contexto real, se define un plan de validación centrado en eficiencia del proceso de preparación, consistencia de las recomendaciones, preservación del conocimiento institucional, usabilidad y utilidad percibida por asesores, así como en la calidad técnica de la recomendación. Como contribución, se entrega una solución de referencia que integra diseño pedagógico, arquitectura de software y trazabilidad de decisiones, habilitando iteraciones futuras y ampliaciones del alcance según las necesidades del CJEI.

**Palabras clave:** sistema de recomendación; juegos de mesa; aprendizaje basado en juegos; explicabilidad; preservación del conocimiento.

## **1. Introducción**

La incorporación de juegos de mesa como recurso didáctico ha ganado terreno en la educación superior por su capacidad de promover la construcción de conocimiento el aprendizaje y el desarrollo de habilidades. En la Pontificia Universidad Javeriana Cali el Centro de Juegos y Experiencias Interactivas (CJEI) apoya diversas asignaturas mediante sesiones facilitadas por asesores y la creación de juegos educativos. No obstante la selección del juego adecuado para cada contexto de clase depende hoy del criterio experto y de búsquedas manuales, sin apoyo tecnológico que soporte la integración sistematizada de juegos disponibles, habilidades y objetivos de aprendizaje, ni mecanismos digitales para capturar y transferir el conocimiento generado. Este estado conduce a tiempos altos de preparación, variabilidad en la calidad de las recomendaciones, baja trazabilidad de las decisiones, uso desigual del catálogo y curva de aprendizaje alta cuando hay rotación de asesores. Ante este escenario, se plantea el diseño e implementación de un sistema de recomendación que, a partir de metadatos de la plataforma BoardGameGeek y del catálogo institucional, y mediante técnicas de procesamiento de lenguaje natural y aprendizaje automático, relacione cada juego con objetivos de clase y habilidades (primarias y secundarias) para ofrecer recomendaciones justificadas y trazables. El prototipo contemplará una interfaz de consulta para asesores y un esquema de retroalimentación post, partida que permita el mejoramiento continuo y la preservación del conocimiento organizacional. El proyecto de carácter aplicado y enfoque mixto, comprende la extracción y normalización de datos, la construcción de una taxonomía de habilidades el desarrollo del motor de recomendación y su evaluación con usuarios del CJEI. Se espera con este proyecto reducir tiempos de selección, mejorar la consistencia y diversificar el uso del catálogo, fortaleciendo a la vez la transferencia de conocimiento. Asimismo se establecen consideraciones éticas, alcances y limitaciones, con miras a sentar bases metodológicas para la incorporación responsable de IA en procesos pedagógicos mediados por juegos de mesa.

### **1.1. Planteamiento del problema**

En el ámbito de la educación superior se ha incrementado el uso de juegos de mesa y otras experiencias lúdicas como estrategia de aprendizaje activo para promover habilidades como el pensamiento crítico, la resolución de problemas el trabajo colaborativo y la comunicación. La incorporación de estos recursos exige que la selección de cada juego se alinee con objetivos de aprendizaje específicos, condiciones operativas de la clase (tiempo disponible, tamaño del grupo,

idioma) y características de los estudiantes, de modo que el uso del juego aporte valor pedagógico y no se limite a una actividad recreativa aislada. En este contexto el Centro de Juegos y Experiencias Interactivas (CJEI) de la Pontificia Universidad Javeriana Cali emplea juegos de mesa como recurso didáctico para apoyar el logro de objetivos de aprendizaje en diversas asignaturas de todas las carreras de la institución. La selección de cada juego depende hoy en gran medida, del criterio experto de los asesores, apoyados en búsquedas manuales ( BoardGameGeek (BGG) y catálogo propio) y experiencias previas. Actualmente no existe apoyo tecnológico para mapear cada juego con habilidades primarias y secundarias, y objetivos pedagógicos, ni un mecanismo digital para capturar y transferir el conocimiento que se genera en la práctica. En consecuencia se observan tiempos prolongados para preparar recomendaciones por clase, variabilidad en la pertinencia de las recomendaciones entre asesores y entre cursos, pérdida de conocimiento cuando un asesor se retira (alta dependencia del conocimiento tácito) baja trazabilidad de por qué se eligió un juego (difícil justificar la decisión ante objetivos de clase) uso desigual del catálogo (sobreutilización de títulos conocidos y subutilización de otros potencialmente pertinentes) y desalineaciones puntuales entre requisitos operativos (duración, número de jugadores, dependencia del idioma, disponibilidad) y las condiciones reales de clase. Estas situaciones se relacionan con la ausencia de una representación institucional unificada que relacione juegos, habilidades y objetivos de aprendizaje; con la dispersión y heterogeneidad de los metadatos disponibles (duración, dureza, mecánicas, idioma) entre BGG y el catálogo del CJEI; y con la carencia de mecanismos analíticos que combinen atributos del juego con reglas pedagógicas y retroalimentación post, partida de forma estructurada. En este escenario el CJEI enfrenta el desafío de consolidar un mecanismo reproducible y explicable que preserve el conocimiento generado (criterios, casos de uso, resultados de sesiones) reduzca tiempos de preparación y mejore la consistencia de las recomendaciones, alineadas con las condiciones de la clase y los objetivos de aprendizaje especialmente a medida que crece la demanda de cursos y sesiones atendidas.

### **1.1.1. Formulación del problema**

Entonces la pregunta a resolver sería: ¿Cómo diseñar e implementar un prototipo de un sistema de recomendación inteligente que, usando especificaciones pedagógicas del CJEI, sugiera juegos de mesa adecuados a objetivos de clase y contexto, preserve el conocimiento institucional y mejore la eficiencia y consistencia de la selección?

### **1.1.2. Sistematización del problema**

Para resolver esta pregunta se deben tener en cuenta las siguientes subpreguntas:

1. ¿Cómo se caracteriza actualmente el uso de los juegos de mesa en el CJEI en términos de objetivos de clase, habilidades promovidas y condiciones operativas (tiempo, tamaño de grupo, idioma, disponibilidad)?
2. ¿Qué taxonomía de juegos de mesa, habilidades y objetivos de aprendizaje resulta pertinente para el CJEI y cómo puede estructurarse a partir de las fuentes disponibles (BGG y catálogo interno)?
3. ¿Cuáles son los requerimientos funcionales y no funcionales que debe cumplir el prototipo de sistema de recomendación inteligente para apoyar a los asesores en la selección de juegos de mesa según objetivos de clase y contexto?
4. ¿Cómo desarrollar el modelo de recomendación que combine las especificaciones pedagógicas del CJEI con los atributos de los juegos para generar sugerencias explicables y alineadas con cada situación de clase?
5. ¿En qué medida el prototipo de sistema de recomendación contribuye a mejorar la eficiencia (tiempos de preparación) la consistencia de las recomendaciones y la preservación del conocimiento institucional, según métricas definidas y la percepción de los asesores del CJEI?

## **1.2. Objetivos**

### **1.2.1. Objetivo general**

Desarrollar un prototipo de sistema de recomendación inteligente de juegos de mesa que, a partir de las especificaciones pedagógicas del CJEI y de los atributos de los juegos, sugiera alternativas alineadas con los objetivos de clase y el contexto de uso, contribuyendo a preservar el conocimiento institucional y a mejorar la eficiencia y consistencia en la selección realizada por los asesores del CJEI.

### **1.2.2. Objetivos específicos**

Caracterizar el uso actual de los juegos de mesa en el CJEI en términos de objetivos de clase, habilidades promovidas y condiciones operativas de las sesiones (tiempo disponible, tamaño de grupo, dependencia de idioma, disponibilidad de juegos)

Diseñar y documentar una taxonomía que relacione juegos de mesa, habilidades y objetivos de aprendizaje, a partir de la integración y normalización de metadatos provenientes de BoardGameGeek (BGG) y del catálogo del CJEI, incluyendo atributos como duración, dificultad, número de jugadores, mecánicas, dependencia de idioma, disponibilidad y posición en el ranking general de BGG.

Especificar los requerimientos funcionales y no funcionales del prototipo de sistema de recomendación y de su herramienta web, incorporando criterios de trazabilidad de los criterios de selección, identidad visual acorde al CJEI y necesidades de uso por parte de los asesores pedagógicos.

Desarrollar e implementar el prototipo del sistema de recomendación para la ludoteca del CJEI, combinando filtrado basado en contenido, reglas pedagógicas y retroalimentación de uso e incorporando el modelado de habilidades primarias y secundarias trabajadas por cada juego mediante análisis de texto (NLP)

Evaluar la precisión, utilidad, usabilidad e impacto del prototipo en términos de tiempos de preparación, consistencia de las recomendaciones y preservación del conocimiento institucional, mediante pruebas piloto y recolección de retroalimentación con asesores del CJEI.

### **1.3. Justificación**

#### **1.3.1. Utilidad**

Este proyecto es de utilidad para el CJEI y para la Pontificia Universidad Javeriana Cali porque responde a una necesidad concreta en la selección de juegos de mesa para experiencias de aprendizaje basado en juegos, la cual depende hoy del criterio experto de los asesores y de búsquedas manuales en fuentes como el catálogo interno y la BoardGameGeek (BGG) generando inversión de tiempo, variabilidad en las recomendaciones y dificultades para justificar la elección de cada juego frente a los objetivos de clase. Un sistema de recomendación inteligente que integre especificaciones pedagógicas del CJEI con los atributos de los juegos permite reducir tiempos de preparación, ofrecer sugerencias más consistentes y trazables, aprovechar mejor el catálogo evitando la sobreutilización de unos pocos títulos y la subutilización de otros, y registrar criterios y resultados de uso para que futuras recomendaciones se apoyen en la experiencia acumulada,

convirtiéndose así en un apoyo directo a la labor cotidiana de asesores y docentes que utilizan juegos de mesa como recurso didáctico.

### **1.3.2. Impacto**

El impacto se proyecta en los planos pedagógico, institucional y académico: en lo pedagógico, un mejor alineamiento entre juegos, habilidades y objetivos de aprendizaje favorece que las experiencias lúdicas se integren de forma estratégica a las asignaturas, potenciando habilidades como el pensamiento crítico, la resolución de problemas el trabajo colaborativo y la comunicación; en lo institucional el CJEI obtiene un mecanismo reproducible y explicable para la selección de juegos que fortalece la memoria organizacional, reduce la dependencia del conocimiento tácito de asesores específicos, facilita la inducción de nuevos asesores y respalda escenarios de crecimiento en la demanda de cursos, permitiendo justificar decisiones ante docentes y programas académicos con mayor transparencia; y en lo académico el proyecto aporta un caso de estudio en la intersección entre aprendizaje basado en juegos, sistemas de recomendación y análisis de texto, generando insumos para futuras investigaciones en analítica del aprendizaje y tecnologías educativas a partir de la construcción de una taxonomía juegos, habilidades, objetivos y de la combinación de filtrado basado en contenido, reglas pedagógicas y retroalimentación de uso.

### **1.3.3. Viabilidad**

Este proyecto es viable técnica y metodológicamente porque cuenta con fuentes de datos consolidadas, la API de BGG y el catálogo de la ludoteca del CJEI, que proporcionan los metadatos necesarios para describir los juegos (duración, dificultad, número de jugadores, mecánicas, idioma entre otros) así como con un contexto real de aplicación en el CJEI, donde los asesores pueden participar en la definición de especificaciones pedagógicas, la codificación experta de habilidades y la validación del prototipo mediante pruebas piloto; adicionalmente las tecnologías requeridas para el procesamiento de datos el análisis de texto y la implementación de un sistema de recomendación basado en contenido y reglas son accesibles y están ampliamente documentadas, y el alcance acotado al desarrollo de un prototipo funcional con una evaluación inicial es coherente con los tiempos, recursos y nivel de profundidad esperados en un trabajo de grado de pregrado, lo que refuerza la factibilidad del proyecto.

#### **1.4. Alcances y Limitaciones**

- Cobertura: juegos de mesa disponibles tanto en la BGG como en el CJEI.
- Usuarios: asesores pedagógicos del CJEI.
- Entorno: recomendación para experiencias de aprendizaje basado en juegos.
- Fuera de alcance: logística de inventario, compra; analítica de rendimiento académico
- post, curso (solo recolección cualitativa post, partida)

## 2. Marco Teórico y Trabajos Relacionados

### 2.1. Marco de referencia

#### 2.1.1. Marco teórico

##### 2.1.1.1. *Sistemas de recomendación [1]*

Los sistemas de recomendación son herramientas de filtrado de información que sugieren a cada usuario aquellos elementos (productos, contenidos etc) más acordes a sus preferencias, ayudando a manejar la sobrecarga de información en entornos digitales. Una definición clásica los describe como sistemas que agregan entradas (valoraciones, interacciones) de múltiples personas para brindar recomendaciones personalizadas a cada usuario objetivo. En términos generales, la literatura especializada clasifica los sistemas de recomendación en tres categorías principales [2]:

- Filtrado basado en contenido: Recomienda elementos o artículos similares a aquellos que el usuario ha apreciado en el pasado, utilizando las características intrínsecas de los artículos en cuestión. Por ejemplo, si un usuario ha disfrutado cierto libro, un recomendador de contenido puede sugerir otros libros del mismo autor, género o con palabras clave parecidas. Este enfoque construye un perfil del usuario a partir de las características de elementos que le han gustado, y luego busca elementos cuyos atributos coincidan con dicho perfil. Una ventaja es que no requiere datos de otros usuarios, haciendo énfasis en las preferencias individuales y pudiendo mitigar ciertos problemas como el arranque en frío de usuarios (usuarios nuevos sin historial) mientras los elementos tengan descripciones suficientes. Sin embargo tiende a recomendar dentro de un mismo tipo de contenido y requiere disponer de metadatos ricos de los elementos.

- Filtrado colaborativo: Recomienda elementos basándose en la similitud entre usuarios o entre elementos según las valoraciones o comportamientos registrados. En esencia, asume que “usuarios con gustos similares en el pasado tendrán gustos similares en el futuro”. Un sistema colaborativo típico agrupa usuarios por comportamiento similar (historial de calificaciones, compras, clics etc) y sugiere a un usuario elementos que otros de su grupo han disfrutado. Alternativamente, puede encontrar similitudes entre elementos (por ejemplo, usuarios que vieron la película A también suelen ver B) y recomendar en función de ello. Este enfoque no necesita conocer las características de los elementos, sino solo las interacciones usuario, elemento, lo que

le permite descubrir preferencias latentes y sorprender al usuario con contenido diverso. Como contrapartida, sufre el problema de escasez o sparsity cuando hay pocos datos y el de arranque en frío cuando llegan usuarios o elementos nuevos sin historial. Además, puede implicar compartir datos de usuarios, planteando desafíos de privacidad. En la práctica este método ha sido muy exitoso; por ejemplo, la conocida función “los clientes que compraron

X también compraron Y” de Amazon se basa en filtrado colaborativo de elemento a elemento.

- Enfoques híbridos: Combinan múltiples técnicas (colaborativas, de contenido, conocimiento experto, demográficas etc) para aprovechar las fortalezas de cada una y paliar sus limitaciones. Actualmente, muchos sistemas comerciales emplean enfoques híbridos, ya que pueden ofrecer recomendaciones más precisas y robustas que los métodos puros. La hibridación puede realizarse de varias maneras: por ejemplo, generando recomendaciones colaborativas y de contenido por separado y luego combinándolas con un peso; incorporando características de contenido dentro de un modelo colaborativo; o usando un modelo unificado que integra ambas fuentes de información. Estas estrategias permiten solucionar problemas típicos como el arranque en frío y la sparsity al complementar datos de usuarios con datos de elementos y viceversa. Un caso emblemático es Netflix, cuyo sistema de recomendación emplea un enfoque híbrido: compara los hábitos de visualización de usuarios similares (filtrado colaborativo) y además sugiere películas con características semejantes a las que cada usuario ha evaluado positivamente (filtrado de contenido). De hecho, tras el concurso Netflix Prize (2009) Netflix adoptó un modelo híbrido para mejorar la precisión de sus recomendaciones. Este tipo de soluciones híbridas se ha vuelto un estándar en la industria, presentes en comercio electrónico, redes sociales y servicios de streaming.

[5] Vale la pena mencionar que el campo de sistemas de recomendación ha evolucionado constantemente. Revisiones influyentes [3] sentaron las bases conceptuales de la generación siguiente de recomendadores, mientras que otros trabajos clásicos definieron formalmente estos sistemas o exploraron exhaustivamente las variantes híbridas posibles. Más recientemente, la investigación incorpora técnicas de aprendizaje profundo (por ejemplo, usando modelos de deep learning para predecir preferencias latentes) y enfoques de aprendizaje por refuerzo, viendo la recomendación como un problema secuencial que optimiza la interacción con el usuario. No obstante los principios fundamentales, filtrado colaborativo, de contenido y sus combinaciones,

continúan siendo el marco de referencia para diseñar soluciones de recomendación efectivas en diversas aplicaciones.

### ***2.1.1.2. Representación semántica con NLP***

La representación semántica de contenido mediante técnicas de Procesamiento de Lenguaje Natural (NLP) consiste en encontrar formas de codificar el significado de palabras, frases o documentos en una forma computable (vectores espacios semánticos, redes) que capture las similitudes y relaciones de significado más allá de la mera forma de las palabras. En otras palabras, busca representar texto de tal modo que la proximidad en la representación refleje proximidad de significado. Este es un fundamento clave para habilitar funciones como comprensión de texto por máquinas, búsqueda semántica, desambiguación de términos y también recomendaciones basadas en contenido textual.

Un principio subyacente es la llamada hipótesis distribucional, resumida como: “palabras que aparecen en contextos similares tienden a tener significados similares” Sobre esta idea se construyó uno de los primeros enfoques importantes el Análisis Semántico Latente (LSA, por sus siglas en inglés) introducido a finales de los 80. LSA toma una gran colección de documentos y construye una matriz término, documento (donde cada celda refleja, por ejemplo, la frecuencia de la palabra  $i$  en el documento  $j$ ) Luego aplica descomposición en valores singulares (SVD) para reducir la dimensionalidad de esa matriz extrayendo factores latentes que representan conceptos subyacentes El resultado es que palabras con significados relacionados acaban teniendo representaciones vectoriales similares en este espacio latente, aun si no coinciden exactamente en texto. LSA permitió por primera vez capturar relaciones semánticas ocultas (sinonimia, temas comunes) de forma automática, y encontró aplicaciones en recuperación de información (bajo el nombre Latent Semantic Indexing) [7] y evaluación automática de textos entre otros Sin embargo tenía limitaciones como el alto costo computacional para grandes corpus y la incapacidad de manejar polisemia correctamente con una única representación por palabra. El campo dio un gran salto con la llegada de los word embeddings (vectores de palabras) basados en redes neuronales. En 2013, Tomas Mikolov y colaboradores en Google introdujeron Word2Vec, un algoritmo que entrena una red neuronal simple para generar vectores para cada palabra, de manera que palabras que aparecen en contextos similares tengan vectores cercanos en el espacio Word2Vec popularizó la idea de representaciones continuas densas donde cada dimensión del vector captura rasgos semánticos

latentes. Un resultado famoso de Word2Vec es que las operaciones aritméticas con sus vectores reflejan relaciones semánticas analógicas: por ejemplo,  $\text{vector}(\text{"Madrid"}) + \text{vector}(\text{"España"}) - \text{vector}(\text{"Francia"}) \approx \text{vector}(\text{"París"})$  demostrando que el modelo había capturado conceptos de capitales de país. Estos embeddings lograron representar con eficacia similitudes léxicas y semánticas: palabras como “walk” y “run” aparecen cercanas, al igual que “bank” (río) y “shore”, o “king” y “queen” mostrando relaciones de género. A diferencia de LSA, los embeddings neuronales pueden entrenarse en corpus masivos (Word2Vec fue entrenado con decenas de miles de millones de palabras) y actualizarse incrementalmente. Su eficiencia y calidad impulsaron multitud de aplicaciones, desde análisis de sentimiento hasta motores de recomendación de contenido. De hecho en sistemas de recomendación de contenido textual es común utilizar embeddings de palabras o de documentos para calcular similitudes semánticas entre lo que un usuario ha consumido y nuevos elementos candidatos. [8] Una limitación de Word2Vec y modelos similares (GloVe, fastText) es que asignan una única representación por palabra, independientemente del contexto en que aparezca. Esto dificulta manejar la polisemia: por ejemplo, la palabra “banco” significando entidad financiera o orilla de río tendría el mismo vector fijo. La última generación de técnicas NLP aborda este problema con modelos de lenguaje contextuales basados en redes neuronales profundas del tipo Transformers. Un hito fue BERT (Bidirectional Encoder Representations from Transformers) BERT es un modelo con cientos de millones de parámetros entrenado en enormes cantidades de texto de manera

auto, supervisada, y tiene la capacidad de producir vectores distintos para una misma palabra según el contexto específico en que aparezca. Por ejemplo, para “bank” en river bank versus bank deposit, BERT generará embeddings diferentes que reflejan cada acepción. Además de embeddings a nivel de palabra, BERT y sus sucesores (GPT, RoBERTa etc) proporcionan representaciones de oraciones o documentos completos, capturando relaciones semánticas más amplias [9]. Estas representaciones contextuales han llevado el desempeño en tareas de NLP a nuevos niveles, logrando comprensión casi humana en tareas como preguntas y respuestas, inferencia textual y resumen automático. En términos prácticos, la representación semántica mediante NLP se ha incorporado en numerosos casos de uso. Por ejemplo, los motores de búsqueda modernos ya no solo emparejan palabras clave, sino que utilizan embeddings para entender la intención del usuario y el significado de la consulta, ofreciendo resultados más relevantes. En sistemas de recomendación de artículos o noticias, se utilizan vectores semánticos de los textos para encontrar

contenido similar en tema o estilo al que le ha gustado al usuario, incluso si no comparten palabras clave exactas. Plataformas como IBM Watson han empleado representaciones semánticas y conocimiento ontológico para responder preguntas en lenguaje natural, ilustrando el poder de combinar NLP con bases de conocimiento. Asimismo en el dominio de juegos educativos o de entretenimiento, técnicas de NLP pueden usarse para representar las habilidades o contenidos (por ejemplo, describir las misiones de un juego en un espacio semántico) y así recomendarle al jugador las misiones más adecuadas según su progreso, cerrando el círculo entre recomendación, habilidad y semántica.

En resumen, la representación semántica con NLP ha evolucionado desde enfoques estadísticos lineales como LSA hasta complejos modelos neuronales contextuales. Autores como Scott Deerwester (LSA) o Tomas Mikolov (Word2Vec) sentaron hitos importantes, y más recientemente Jacob Devlin y colaboradores con BERT marcaron la pauta de la era de los Transformers [36]. Estas técnicas proporcionan el fundamento para que las máquinas "entiendan" textos y puedan compararlos por su significado. En el contexto de esta investigación, dominar la representación semántica permitirá, por ejemplo, analizar descripciones de elementos o interacciones en un juego y extraer de ellas características relevantes que, combinadas con un sistema de recomendación y un modelo de habilidades, contribuyan a una solución integral más inteligente. Las investigaciones actuales continúan refinando estos modelos (por ejemplo, modelos multilingües, adaptaciones más ligeras como DistilBERT, o combinaciones con conocimiento explícito) para lograr representaciones semánticas cada vez más precisas y útiles en aplicaciones del mundo real.

### ***2.1.1.3. Aprendizaje basado en juegos y el uso de juegos de mesa en educación***

El Aprendizaje Basado en Juegos (ABJ, conocido en inglés como Game, Based Learning, GBL) se refiere a una metodología educativa activa que integra juegos en el proceso de enseñanza, aprendizaje con el fin de motivar al estudiante y facilitar la comprensión de contenidos. En este enfoque el juego en sí mismo se convierte en la actividad principal a través de la cual se logran objetivos formativos, aprovechando la participación lúdica como motor del aprendizaje [32]. A diferencia de la gamificación, que incorpora elementos de juego en contextos no lúdicos el GBL implica el uso de juegos completos diseñados o adaptados con intencionalidad pedagógica. Dentro de estas estrategias lúdicas, los juegos de mesa ocupan un lugar destacado como recurso didáctico. De hecho el uso pedagógico de juegos de mesa se considera parte integral del GBL y ha

demostrado ser una alternativa eficaz y tangible para trabajar competencias académicas y cognitivas en el aula, complementando a los recursos digitales [19]. Los juegos de mesa, ya sean comerciales adaptados o diseñados por docentes, permiten al profesor abordar contenidos curriculares de forma interactiva, reforzando conceptos de la asignatura a la vez que desarrollan habilidades en los estudiantes [19]. En esencia el GBL con juegos de mesa sitúa al estudiante en un contexto de aprendizaje activo y participativo, donde aprender y jugar forman parte de una misma experiencia enriquecedora. Beneficios pedagógicos de los juegos de mesa en el aula

Numerosas investigaciones respaldan los beneficios pedagógicos de incorporar juegos de mesa en contextos educativos reales. En términos generales, los estudios coinciden en que los juegos de mesa bien implementados aportan mejoras en tres grandes ámbitos: el académico el social y el afectivo, motivacional [33]. A continuación, se destacan algunos beneficios específicos identificados en la literatura:

- Mayor motivación y participación activa: El carácter lúdico de los juegos de mesa

incrementa la motivación intrínseca de los estudiantes. Aprender mediante el juego resulta más atractivo y estimulante, lo que se traduce en un mayor grado de implicación en la tarea escolar [32]. La inmediatez de la retroalimentación y las recompensas dentro del juego (ganar puntos, resolver un reto) genera entusiasmo por seguir aprendiendo [19]. Este componente motivacional contribuye a que los estudiantes perciban el aprendizaje como algo divertido y relevante, mejorando su actitud hacia la escuela. Además, diversos autores han reportado que la introducción regular de juegos de mesa puede incluso impactar positivamente el rendimiento académico en áreas como matemáticas y lectura, al fomentar una práctica adicional de estos contenidos en un entorno lúdico [34].

- Desarrollo de pensamiento crítico y habilidades de resolución de problemas: Muchos

juegos de mesa especialmente los de estrategia, lógica o acertijos, obligan a los participantes a analizar situaciones, planificar movidas y tomar decisiones para alcanzar sus objetivos. Esta dinámica lúdica entrena el pensamiento crítico y la capacidad de resolución de problemas en los estudiantes [35]. Por ejemplo, un estudio en *Frontiers in Psychology* encontró que los niños que participan regularmente en juegos de mesa que requieren estrategia presentan mejoras significativas en habilidades cognitivas como la

atención, la memoria de trabajo y el razonamiento lógico [35]. Asimismo se ha explorado el impacto específico del ABJ con juegos de mesa en el pensamiento lógico, matemático y la resolución de problemas: en educación secundaria, una intervención basada en un juego de mesa mejoró la competencia para resolver problemas complejos de forma significativa frente a métodos tradicionales [36]. En síntesis el entorno seguro de un juego permite a los alumnos ensayar estrategias equivocarse y aprender de sus errores, transfiriendo posteriormente estas habilidades de pensamiento crítico al mundo real.

- Fomento de la colaboración y habilidades sociales: Los juegos de mesa típicamente implican interacción cara a cara, ya sea en modalidad competitiva o cooperativa. En el aula esto se traduce en oportunidades para que los estudiantes trabajen en equipo, negocien reglas, compartan turnos y se comuniquen eficazmente. Especialmente en juegos cooperativos (donde todos ganan o pierden juntos) los estudiantes aprenden la importancia de la colaboración, la empatía y el respeto por las contribuciones de sus compañeros. Investigaciones señalan que estas experiencias lúdicas favorecen un clima de aula más integrado e inclusivo, donde los estudiantes desarrollan habilidades de cooperación, comunicación y manejo de conflictos [32][38]. Incluso en juegos competitivos, los niños deben seguir normas y aceptar resultados (ganar o perder) lo cual refuerza valores de respeto, fair play y tolerancia. En conjunto, los juegos de mesa actúan como un laboratorio social en pequeña escala, potenciando las habilidades socioemocionales y las relaciones positivas entre pares dentro del aula [32].

- Mejora de la autoestima y gestión emocional: Participar en juegos conlleva afrontar retos, asumir riesgos controlados y manejar la frustración cuando las cosas no salen como se espera. En contextos educativos, se ha observado que los juegos de mesa ayudan a los alumnos a desarrollar tolerancia a la frustración y resiliencia [37]. Al jugar, los niños experimentan tanto éxitos como fracasos en un entorno seguro: aprenden a manejar la ansiedad que puede generar equivocarse, a perseverar tras un intento fallido y a controlar impulsos (por ejemplo esperar su turno antes de actuar) Este proceso contribuye a una mejor autorregulación emocional. Algunos autores destacan que ciertos juegos, por su estructura, favorecen también la empatía y la comprensión de distintas perspectivas especialmente cuando los estudiantes deben ponerse en el lugar de otros jugadores o personajes [38]. En suma el uso pedagógico de juegos de mesa no solo transmite conocimientos,

sino que forma al estudiante integralmente, fortaleciendo su autoconfianza y habilidades emocionales.

En conjunto, la literatura respalda que integrar juegos de mesa en la enseñanza puede generar experiencias de aprendizaje más significativas y completas, al combinar contenido académico con desarrollo de habilidades blandas. No obstante cabe señalar que varios autores sugieren la necesidad de más investigación empírica para determinar con precisión la efectividad de estas estrategias lúdicas a largo plazo y delimitar en qué condiciones funcionan mejor [33]. Pese a ello, los hallazgos actuales resultan prometedores en cuanto al potencial educativo de los juegos de mesa. Ejemplos de aplicaciones educativas de juegos de mesa El enfoque de aprendizaje basado en juegos de mesa ha sido llevado a la práctica en diversos niveles educativos y áreas de contenido, con resultados positivos documentados en la literatura. A continuación, se describen algunos ejemplos y estudios de caso relevantes:

- Matemáticas básicas [20] [39]: ELEGAR es un juego de mesa diseñado por docentes para reforzar las operaciones aritméticas básicas en Educación Primaria. En un estudio con alumnos de 8 a 10 años, reportan que la introducción de ELEGAR en el aula permitió a los niños disfrutar practicando sumas, restas y multiplicaciones, mejorando su agilidad de cálculo y su actitud hacia las matemáticas [39]. Los estudiantes manifestaron mayor interés y menor ansiedad al enfrentar ejercicios aritméticos a través del juego en contraste con métodos tradicionales [39]. Este caso ilustra cómo un juego de mesa bien diseñado puede abordar contenidos curriculares específicos (operaciones matemáticas) a la vez que engancha a los alumnos en una experiencia lúdica.

- Ciencias de la salud [40]: En el ámbito de la educación en hábitos saludables, desarrollaron e implementaron un juego de mesa educativo para enseñar conceptos de nutrición y actividad física a estudiantes de primaria y secundaria [40]. El juego introducía desafíos y preguntas relacionadas con alimentación balanceada, tipos de alimentos y ejercicio, todo en formato lúdico. Los resultados indicaron que los participantes no solo adquirieron conocimientos sobre nutrición, sino que mostraron una actitud más reflexiva frente a sus propias elecciones alimenticias [40]. Este estudio de caso resalta que los juegos de mesa pueden adaptarse a contenidos de ciencias naturales y promover aprendizajes aplicados a la vida cotidiana (en este caso, fomentar una alimentación saludable)

- Ciencias naturales (astronomía y física) [41]: Cardinot y Fairfield, doctores en astronomía y física, diseñaron un juego de mesa para complementar la enseñanza de astronomía en la educación secundaria. En su investigación, un grupo de estudiantes jugó regularmente a este juego que simulaba misiones espaciales y fenómenos astronómicos, integrando conceptos de física y astronomía en la mecánica del juego. Se observó que el uso del juego incrementó significativamente el interés y la participación de los alumnos en clase, a la par que mejoró su comprensión de conceptos como órbitas planetarias y propiedades de los astros [41]. Los estudiantes involucrados reportaron sentirse más motivados para aprender ciencia gracias al formato interactivo y competitivo del juego. Este ejemplo muestra el potencial de los juegos de mesa para abordar contenidos científicos complejos de forma accesible y atractiva.

- Habilidades de resolución de problemas [36]: Un estudio realizado en Tailandia en el año 2023 evaluó la efectividad de un programa de aprendizaje basado en juegos de mesa enfocado en mejorar la competencia de resolución de problemas en estudiantes de secundaria. Tras varias sesiones de juego diseñadas para ejercitar el pensamiento lógico y la toma de decisiones, los investigadores hallaron mejoras estadísticamente significativas en las habilidades de resolución de problemas de los alumnos en comparación con un grupo de control que siguió clases convencionales. Este caso refuerza la idea de que los juegos de mesa, al enfrentar a los estudiantes con desafíos que deben solucionar de forma creativa, pueden desarrollar competencias cognitivas de alto nivel útiles para las materias STEM y la vida diaria. Otros ejemplos en la literatura incluyen juegos de mesa para la enseñanza de la química, como adaptaciones del juego de Battleship para aprender la tabla periódica [42], juegos de cartas para educar sobre el valor nutricional de los alimentos [43] e incluso materiales lúdicos para aprender historia y lengua. En todos estos casos, se enfatiza la importancia de que el juego esté alineado con objetivos educativos claros y venga acompañado de una adecuada orientación del docente para maximizar su impacto en el aprendizaje.

#### ***2.1.1.4. Consideraciones para la selección y adaptación de juegos de mesa didácticos***

Para aprovechar al máximo el potencial educativo de los juegos de mesa es imprescindible planificar cuidadosamente qué juegos se utilizan y cómo se implementan en el aula. Diversos

autores proporcionan pautas prácticas para la selección y adaptación de juegos de mesa con fines didácticos entre las cuales destacan:

- Definir el objetivo pedagógico: Antes de llevar un juego al aula el docente debe tener claridad sobre el propósito educativo que persigue con esa actividad [44]. Esto implica identificar qué contenidos o habilidades se quieren trabajar mediante el juego (por ejemplo, practicar vocabulario en inglés, reforzar la resolución de ecuaciones, fomentar el trabajo en equipo etc) El juego elegido debe ser pertinente para cumplir dicho objetivo, y no usarse solo como entretenimiento desvinculado del currículo.

- Adecuación al nivel y características de los alumnos [45]: Es fundamental considerar la edad, grado de desarrollo e intereses de los estudiantes al escoger un juego de mesa educativo. Las reglas, la temática y la complejidad del juego deben ser apropiadas para los estudiantes. Por ejemplo, con niños pequeños se recomiendan mecánicas sencillas, instrucciones visuales y partidas cortas, mientras que con adolescentes se pueden emplear juegos de estrategia más elaborados que reten sus capacidades lógicas. Un juego demasiado complejo para la edad de los alumnos puede frustrarlos, y uno demasiado simple puede aburrirlos, por lo que el equilibrio en la dificultad es clave.

- Simplicidad de reglas y tiempo de juego razonable: En el contexto escolar, resulta conveniente evitar juegos con instrucciones ambiguas o excesivamente extensas, así como aquellos que requieran múltiples horas para una sola partida [44]. Un juego de mesa efectivo en clase debería poder explicarse en unos pocos minutos y jugarse dentro del tiempo de una sesión lectiva típica. De esta manera, los alumnos entienden rápidamente la dinámica y se pueden dedicar más tiempo a jugar (y por ende, a practicar las habilidades objetivo) Algunos educadores sugieren la regla del “5, 10, 15”, buscando juegos que tomen alrededor de 5 minutos en explicar las reglas, 10 minutos en jugar una ronda, y cuyo costo sea de aproximadamente 15 euros , lo que suele correlacionar con juegos sencillos y asequibles [44]. Aunque estas cifras son orientativas, la idea central es seleccionar juegos ágiles, de corta duración y rejugables, que permitan realizar varias partidas en una clase si es necesario y mantener la atención de los estudiantes. La rejugabilidad es particularmente importante: si un juego genera en los estudiantes ganas de “jugar otra vez”, incentivará la repetición y la consolidación de los aprendizajes [44].

- Adaptación de juegos comerciales vs. creación propia: El docente puede optar por juegos de mesa comerciales ya existentes, adaptándolos ligeramente al contenido educativo, o bien diseñar juegos originales específicamente con fines didácticos. Según un análisis de la literatura reciente, muchos profesores, investigadores prefieren desarrollar sus propios juegos de mesa educativos para ajustarlos exactamente a sus objetivos curriculares [33]. La ventaja de usar juegos comerciales es que suelen venir probados en su jugabilidad y resultan atractivos para los alumnos; No obstante puede requerir modificar ciertas reglas o incluir preguntas, tarjetas personalizadas para conectar con la materia impartida. Al realizar adaptaciones es importante cuidar que los cambios no perjudiquen la coherencia interna del juego ni su diversión, y que se mantenga el logro del objetivo pedagógico planteado [44]. Por otro lado, crear un juego original ofrece flexibilidad total para incorporar el contenido deseado, pero demanda tiempo de desarrollo, testeo previo y cierto conocimiento de diseño de juegos por parte del docente. En cualquier caso, sea un juego adaptado o nuevo, se aconseja que el profesor lo pruebe de antemano, anticipe dudas de reglas y planifique cómo guiará la sesión.

- Rol activo del docente y debriefing: La implementación exitosa de un juego de mesa educativo no consiste solo en repartir el juego y dejar que los alumnos jueguen libremente; el docente desempeña un rol facilitador crucial antes, durante y después de la partida. Antes de jugar, debe explicar claramente las reglas y vincular el juego con el tema académico que se está abordando. Durante el juego, observará el desempeño de los grupos, resolverá dudas y se asegurará de que todos estén participando y comprendiendo la actividad. Al concluir es muy recomendable conducir un debriefing o sesión de reflexión con los estudiantes [44]. En esta etapa posterior al juego el profesor guía una discusión sobre lo ocurrido en la partida: qué estrategias funcionaron, cómo se aplicaron los conceptos de la materia en el juego, qué dificultades surgieron y cómo se resolvieron etc. Esta reflexión conecta explícitamente la experiencia lúdica con los objetivos de aprendizaje, ayudando a los alumnos a tomar conciencia de lo que han aprendido y a transferir esos conocimientos o habilidades más allá del juego. Estudios didácticos subrayan que esta mediación docente y metacognición final son esenciales para que el aprendizaje basado en juegos tenga un impacto educativo profundo y no se quede solo en “un rato de jugar” [44]. En síntesis, la incorporación de juegos de mesa en contextos formativos requiere una planificación estratégica: elegir el juego adecuado, prepararlo pedagógicamente, y acompañar a los estudiantes

durante la actividad lúdica para orientar el aprendizaje. Cuando se siguen estas consideraciones, los juegos de mesa pueden convertirse en potentes aliados didácticos, aportando variedad metodológica e innovación al aula de ingeniería de sistemas (y a otras áreas) y propiciando un aprendizaje activo, significativo y motivador. Las evidencias recopiladas sugieren que el esfuerzo de integrar juegos de mesa en la enseñanza vale la pena, siempre que se realice de manera reflexiva y alineada con los objetivos educativos. De este modo el aprendizaje basado en juegos de mesa puede contribuir tanto al éxito académico como al desarrollo integral de los estudiantes, preparando un terreno fértil para una educación más dinámica y centrada en el estudiante.

## **2.2. Trabajos relacionados**

### **2.2.1. Sequential Recommendations on Board, Game Platforms [22]**

Este estudio pionero implementó sistemas de recomendación secuenciales específicamente para plataformas de juegos de mesa, utilizando un dataset masivo de BoardGameGeek con 511,960 usuarios, 108,536 juegos y más de 47 millones de valoraciones. Se emplearon algoritmos de deep learning como GRU4Rec (Redes Neuronales Recurrentes con GRU) Caser (redes neuronales convolucionales) y SASRec (redes auto, atencionales) para predecir las preferencias de los usuarios basándose en sus secuencias de interacción con juegos. El enfoque se centra en el filtrado colaborativo utilizando patrones secuenciales de comportamiento de usuarios para recomendar nuevos juegos.

Este trabajo establece un precedente importante al demostrar la viabilidad técnica de sistemas de recomendación en el dominio específico de juegos de mesa usando datos de BGG, logrando precisiones de 0.19 (Precision@10) y NDCG de 0.36. Aporta metodologías para la extracción y procesamiento del dataset de BGG, así como métricas de evaluación apropiadas para este dominio. Sin embargo se diferencia del proyecto propuesto en aspectos fundamentales (1) utiliza únicamente filtrado colaborativo basado en comportamiento de usuarios sin considerar objetivos pedagógicos (2) no incorpora análisis semántico de contenido mediante NLP para clasificar habilidades (3) está orientado a usuarios generales de juegos en contextos recreativos, no educativos, y (4) no integra restricciones operativas de clase ni retroalimentación de experiencias pedagógicas. El presente proyecto extiende este trabajo al contexto educativo mediante un sistema

híbrido que combina contenido (atributos del juego, habilidades extraídas por NLP) con reglas pedagógicas expertas y feedback post, sesión.

### **2.2.2. Personalized Online Learning Resource Recommendation Based on Artificial Intelligence**

Este estudio desarrolló un sistema de recomendación personalizado de recursos de aprendizaje en línea que integra teorías de psicología educativa (Zona de Desarrollo Próximo, modelo de Bloom, teoría de carga cognitiva) con técnicas de inteligencia artificial. Utiliza un algoritmo LinUCB modificado con coeficiente de exploración personalizado que considera la habilidad del estudiante calculada a partir de comportamientos de aprendizaje (fracción de participación, grado de completitud, tasa de respuestas correctas) El sistema clasifica estudiantes en tres grupos (activos, potenciales, inactivos) mediante K, means y extrae atributos de videos educativos (tasa de aprendizaje, grado promedio de completitud, tasa de rebobinado, tasa de respuestas correctas, grado de dificultad) Logró una precisión del 70% para estudiantes activos y demostró adaptabilidad al ajustar la dificultad de recursos recomendados según la capacidad del estudiante. Además este trabajo proporciona un marco conceptual valioso para integrar teorías pedagógicas con sistemas de recomendación mediante inteligencia artificial, demostrando cómo características de estudiantes pueden extraerse de datos comportamentales y cómo la psicología educativa puede guiar decisiones algorítmicas. Aporta metodologías para (1) calcular habilidades, capacidades de usuarios a partir de registros de comportamiento (2) personalizar coeficientes de exploración, explotación según perfiles de usuario (3) evaluar adaptabilidad (matching entre dificultad de recursos y capacidad del estudiante) y personalización del sistema, y (4) clasificar usuarios en grupos con necesidades diferenciadas. No obstante se diferencia del proyecto actual en que (a) recomienda videos educativos individuales en entornos de e, learning asíncrono, no juegos de mesa para experiencias presenciales (b) no utiliza procesamiento de lenguaje natural para extraer habilidades desde descripciones de recursos (c) no maneja restricciones operativas contextuales de sesiones presenciales (duración, número de jugadores, idioma, disponibilidad física) y (d) no integra conocimiento experto de facilitadores pedagógicos ni retroalimentación post, actividad colaborativa. El proyecto propuesto adapta estos principios de personalización pedagógica al dominio de juegos de mesa educativos, incorporando NLP para mapeo automático de habilidades y combinando perfiles de clase con atributos de juegos.

### **2.2.3. Board Game Recommendation Engine , Quantic Foundry [24]**

Quantic Foundry desarrolló un motor de recomendación comercial de juegos de mesa basado en perfiles motivacionales de jugadores. En lugar de recomendar títulos específicos el sistema utiliza una encuesta de 5 minutos para construir un perfil de motivación del jugador en múltiples dimensiones psicométricas (competencia, inmersión estrategia, interacción social etc) y luego genera recomendaciones personalizadas alineadas con ese perfil motivacional. Este enfoque basado en contenido psicológico permite recomendaciones explicables y evita sesgos de popularidad.

Este sistema comercial demuestra la viabilidad de enfoques basados en perfiles psicológicos, motivacionales para recomendación de juegos de mesa, ofreciendo un modelo de interfaz de usuario intuitivo y recomendaciones explicables. Aporta la idea de que las preferencias de juegos pueden capturarse mediante dimensiones latentes de motivación más allá de características superficiales de los juegos. Sin embargo se diferencia sustancialmente del proyecto propuesto (1) está diseñado para jugadores recreativos individuales buscando entretenimiento, no para educadores buscando herramientas pedagógicas (2) no considera objetivos de aprendizaje, habilidades académicas o competencias a desarrollar (3) no integra restricciones operativas de contextos educativos institucionales (disponibilidad en catálogo, restricciones de tiempo de clase, idioma) (4) no captura ni transfiere conocimiento experto de facilitadores pedagógicos, y (5) no incorpora retroalimentación post, sesión para mejora continua del sistema. El presente proyecto toma inspiración del enfoque basado en perfiles pero lo traslada al dominio educativo, sustituyendo perfiles motivacionales por objetivos pedagógicos y habilidades e incorporando restricciones institucionales y retroalimentación experta.

### **2.2.4. Hybrid System for Video Game Recommendation Based on Implicit Ratings and Social**

Networks [25] Este trabajo propone un sistema híbrido de recomendación de videojuegos que combina filtrado colaborativo basado en valoraciones implícitas (tiempo de juego, logros obtenidos) con análisis de redes sociales y grafos de conocimiento. Utilizan algoritmos de teoría de grafos para construir perfiles de interés de usuarios extrayendo información semántica de tweets relacionados con videojuegos, y luego calculan similitud de intereses mediante el grafo de

conocimiento. El sistema genera recomendaciones rankeadas considerando tanto preferencias individuales como influencias sociales.

Este estudio aporta técnicas para (1) utilizar valoraciones implícitas (comportamiento de uso) en lugar de explícitas (calificaciones) (2) integrar análisis de redes sociales para enriquecer perfiles de usuario (3) emplear grafos de conocimiento para representación semántica y cálculo de similitudes, y (4) diseñar arquitecturas híbridas que combinan múltiples fuentes de información. Sin embargo se diferencia del proyecto propuesto en varios aspectos críticos (a) está orientado a videojuegos digitales individuales en contextos de entretenimiento, no juegos de mesa físicos en contextos educativos colaborativos (b) no aborda objetivos de aprendizaje ni habilidades pedagógicas (c) no considera restricciones operativas de sesiones educativas presenciales (d) no incorpora conocimiento experto de facilitadores ni taxonomías de habilidades educativas, y (e) no utiliza NLP para extraer habilidades desde descripciones de juegos. El proyecto actual adapta el concepto de sistema híbrido al dominio educativo, sustituyendo redes sociales y comportamiento de jugadores por reglas pedagógicas expertas, objetivos de clase y retroalimentación de asesores, mientras mantiene la hibridación de contenido (atributos de juegos, análisis semántico NLP) con conocimiento experto.

### **2.2.5. Building Recommendation Systems for Board Games [26]**

Chris Grannan desarrolló un sistema de recomendación de juegos de mesa utilizando dos enfoques principales: filtrado basado en contenido y filtrado colaborativo. El sistema basado en contenido calcula similitudes entre juegos usando características como mecánicas, categorías, peso (complejidad) y número de jugadores extraídas de BoardGameGeek. Implementa medidas de similitud (coseno, Jaccard) sobre representaciones vectoriales de juegos para generar recomendaciones del tipo "si te gustó X, te gustará Y" basándose en atributos compartidos. Este trabajo técnico proporciona implementaciones prácticas de sistemas de recomendación basados en contenido específicamente para juegos de mesa, demostrando cómo extraer y procesar atributos de BGG (mecánicas, categorías, complejidad) para calcular similitudes entre juegos. Aporta código de referencia y metodologías para (1) extracción de metadatos de BGG (2) representación vectorial de juegos (3) cálculo de similitudes mediante diferentes métricas, y (4) generación de recomendaciones basadas en contenido. No obstante se diferencia del proyecto propuesto en aspectos fundamentales (a) no está orientado al contexto educativo ni considera objetivos

pedagógicos o habilidades a desarrollar (b) utiliza únicamente atributos estructurados de BGG sin análisis semántico de descripciones mediante NLP (c) no mapea juegos a habilidades primarias, secundarias (d) no incorpora restricciones operativas de contextos educativos institucionales (disponibilidad en inventario, duración de sesión, idioma) (e) no integra conocimiento experto de facilitadores pedagógicos ni retroalimentación post, sesión, y (f) está diseñado para recomendaciones recreativas usuario, a, usuario, no para asesores pedagógicos seleccionando recursos didácticos. El proyecto actual extiende este enfoque basado en contenido incorporando análisis semántico NLP de descripciones para extraer habilidades, integrando reglas pedagógicas expertas, y adaptando el sistema a restricciones y objetivos del contexto educativo institucional.

#### ***2.2.5.1. Recommender System for Board Games Using Game Concepts [27]***

Este trabajo académico propone formalizar la noción de "concepto de juego" inspirada en términos utilizados por jugadores y diseñadores e implementarla a través del sistema Ludii (General Game System) Describen conceptos en múltiples niveles de abstracción (el juego completo, movimientos estados alcanzados) representados mediante ludemas. Esta representación conceptual facilita aplicaciones como creación de hiper, agentes selectores, transferencia de aprendizaje de IA entre juegos, y explicación de técnicas de IA usando terminología de juegos.

Este trabajo aporta un marco teórico para representar juegos mediante conceptos formales multi, nivel, lo que permite comparaciones semánticas más ricas que simples atributos superficiales. La idea de conceptos de juego formalizados y jerarquizados podría enriquecer representaciones semánticas para sistemas de recomendación. Sin embargo se diferencia significativamente del proyecto propuesto (1) está orientado a inteligencia artificial para juegos y agentes autónomos, no a recomendación para contextos educativos (2) la aplicación de recomendación mencionada es hipotética y no está implementada para usuarios humanos (3) no aborda objetivos pedagógicos, habilidades educativas o contextos de aprendizaje (4) requiere representación formal de juegos en Ludii, lo cual no es aplicable a catálogos comerciales como BGG (5) no integra conocimiento experto de facilitadores ni restricciones operativas de contextos institucionales, y (6) no utiliza técnicas de NLP sobre textos descriptivos para extraer características. El proyecto actual se diferencia al enfocarse en implementación práctica para asesores pedagógicos usando datos disponibles de BGG empleando NLP para extracción automática de habilidades desde

descripciones textuales e integrando conocimiento experto y restricciones del contexto educativo institucional.

Los trabajos revisados abordan sistemas de recomendación en dominios relacionados (juegos de mesa, recursos educativos en línea) utilizando técnicas relevantes (filtrado colaborativo, basado en contenido, NLP, algoritmos híbridos, integración de psicología educativa) Sin embargo ninguno aborda específicamente el problema planteado en este proyecto: Un sistema de recomendación híbrido de juegos de mesa físicos para contextos educativos presenciales que integre (1) análisis semántico NLP de descripciones de juegos para mapeo automático de habilidades (2) restricciones operativas de sesiones educativas (duración, jugadores, idioma, disponibilidad) (3) reglas pedagógicas expertas (4) objetivos de aprendizaje de clase, y (5) retroalimentación post, sesión de asesores pedagógicos.

Este proyecto sintetiza y extiende elementos de los trabajos anteriores: toma técnicas de extracción de datos de BGG y representaciones de juegos [21][26], integra principios de psicología educativa y personalización pedagógica [23], adopta arquitecturas híbridas que combinan contenido con conocimiento experto [24], y propone análisis semántico NLP de textos descriptivos para extracción automática de habilidades (no abordado explícitamente en trabajos previos del dominio) La contribución distintiva es la integración de estos elementos en un sistema aplicado específicamente al contexto institucional de aprendizaje basado en juegos de mesa, con trazabilidad explicabilidad y mecanismos de captura de conocimiento organizacional.

## **3. Metodología**

### **3.1. Enfoque de Prototipado Evolutivo**

#### **3.1.1. ¿En qué consiste?**

Con el propósito de dar cumplimiento a los objetivos planteados, la metodología se centra en el desarrollo de un prototipo de sistema de recomendación de juegos de mesa orientado a asesores pedagógicos que diseñan experiencias de aprendizaje basado en juegos en el CJEI. El enfoque se orienta a la construcción iterativa de un prototipo funcional que integre atributos provenientes de la API de BoardGameGeek (BGG) reglas pedagógicas y retroalimentación de uso de los asesores. Cada objetivo se desarrollará a través de un conjunto de actividades que permitirán avanzar de forma ordenada hasta la entrega y evaluación del prototipo final.

#### **3.1.2. Principios fundamentales**

- Integración de especificaciones pedagógicas del CJEI con atributos de juegos provenientes de BoardGameGeek (BGG) y del catálogo interno.
- Trazabilidad de criterios de selección y registro de resultados de uso para preservar el conocimiento institucional.
- Combinación de filtrado basado en contenido, reglas pedagógicas y retroalimentación de uso, incorporando análisis de texto (NLP) para modelar habilidades primarias y secundarias.
- Validación mediante participación de asesores del CJEI en la definición de especificaciones, codificación experta de habilidades y pruebas piloto del prototipo.

#### **3.1.3. Fases típicas**

- Caracterización del uso actual (objetivos de clase, habilidades promovidas y condiciones operativas)
- Diseño y documentación de la taxonomía juegos, habilidades, objetivos e integración, normalización de metadatos (BGG y catálogo CJEI)
- Especificación de requerimientos funcionales y no funcionales y lineamientos de la herramienta web.
- Desarrollo e implementación del prototipo de recomendación (modelo híbrido , soporte NLP)
- Evaluación inicial del prototipo mediante pruebas piloto y retroalimentación de asesores.

#### **3.1.4. Ventajas y desventajas**

- Ventajas (según el alcance del proyecto): permite avanzar hacia un prototipo funcional con evaluación inicial en un contexto real de aplicación (CJEI) y con tecnologías accesibles y documentadas.
- Desventajas, limitaciones (según el alcance definido): la evaluación se restringe a una validación inicial y se excluyen componentes como la logística de inventario, compra y la analítica de rendimiento académico post, curso.

#### **3.1.5. Cuándo usarlo**

En el contexto de este trabajo el prototipado evolutivo es pertinente cuando se requiere construir un artefacto funcional para apoyar decisiones (selección de juegos) y validar de manera temprana sus criterios y utilidad con usuarios expertos (asesores pedagógicos) bajo un alcance acotado a una implementación inicial y pruebas piloto.

### **3.2. Actividades planificadas**

#### **3.2.1. Caracterizar el uso actual de los juegos de mesa en el CJEI en términos de objetivos de clase, habilidades promovidas y condiciones operativas de las sesiones (tiempo disponible, tamaño de grupo, dependencia de idioma, disponibilidad de juegos)**

1. Identificación en conjunto con los asesores pedagógicos, de los atributos mínimos necesarios para la recomendación (duración, dificultad, número de jugadores, mecánicas, dependencia de idioma, disponibilidad, posición en el ranking entre otros)
2. Consultas y extracción de datos desde la API, archivos de BGG y del catálogo interno del CJEI, consolidando la información en un repositorio único.
3. Normalización y limpieza de los datos recolectados, definiendo formatos escalas y valores por defecto para atributos incompletos o ausentes.
4. Documentación del modelo de datos resultante, incluyendo diccionario de campos y criterios de normalización adoptados.

**3.2.2. Diseñar y documentar una taxonomía que relacione juegos de mesa, habilidades y objetivos de aprendizaje, a partir de la integración y normalización de metadatos provenientes de BoardGameGeek (BGG) y del catálogo del CJEI, incluyendo atributos como duración, dificultad, número de jugadores, mecánicas, dependencia de idioma, disponibilidad y posición en el ranking general de BGG.**

1. Revisión de literatura y de experiencias previas del CJEI sobre uso de juegos de mesa en aula, con el fin de identificar categorías de habilidades (por ejemplo, pensamiento crítico, trabajo colaborativo, negociación, toma de decisiones entre otras)
2. Elaboración de una propuesta inicial de taxonomía de habilidades y criterios para asignar habilidades primarias y secundarias a cada juego.
3. Realización de sesiones de trabajo con asesores pedagógicos para discutir, ajustar y validar la taxonomía de habilidades y las reglas pedagógicas asociadas (por ejemplo, relación entre tipo de juego, tiempo disponible y tamaño del grupo)
4. Asignación de habilidades primarias y secundarias a un subconjunto representativo de juegos del catálogo, registrando las decisiones y criterios aplicados para futuras extensiones.

**3.2.3. Especificar los requerimientos funcionales y no funcionales del prototipo de sistema de recomendación y de su herramienta web, incorporando criterios de trazabilidad de los criterios de selección, identidad visual acorde al CJEI y necesidades de uso por parte de los asesores pedagógicos.**

1. Análisis de necesidades de los asesores pedagógicos a partir de la caracterización inicial y de sesiones de co, diseño, identificando tareas clave relacionadas con la planeación de clases y la selección de juegos de mesa.
2. Formulación de requerimientos funcionales del sistema y de la herramienta web (por ejemplo: búsqueda por objetivos de aprendizaje, filtros por condiciones operativas, visualización de recomendaciones, registro de retroalimentación) utilizando casos de uso o historias de usuario.

3. Definición de requerimientos no funcionales (usabilidad, interpretabilidad de las recomendaciones, rendimiento, disponibilidad, seguridad básica de acceso) y de criterios de trazabilidad que permitan al asesor comprender por qué un juego fue recomendado.
4. Diseño de lineamientos de identidad visual y experiencia de usuario de la herramienta web, alineados con la imagen institucional del CJEI y con las prácticas habituales de los asesores.
5. Elaboración de un documento de especificación de requerimientos que integre los aspectos funcionales, no funcionales, de trazabilidad y de diseño de interfaz como insumo para el desarrollo del prototipo.

#### **3.2.4. Desarrollar e implementar el prototipo del sistema de recomendación para la ludoteca del CJEI, combinando filtrado basado en contenido, reglas pedagógicas y retroalimentación de uso e incorporando el modelado de habilidades primarias y secundarias trabajadas por cada juego mediante análisis de texto (NLP)**

1. Definición en conjunto con los asesores pedagógicos, de un esquema sencillo de retroalimentación sobre las recomendaciones (por ejemplo, valoración de utilidad, selección, uso efectivo del juego recomendado, observaciones cualitativas)
2. Implementación en el prototipo de mecanismos para registrar la retroalimentación de los asesores (campos de evaluación, comentarios o registro de selección de juegos)
3. Ejecución de pruebas piloto con un grupo reducido de asesores del CJEI en un entorno controlado, donde se simulen o documenten casos de uso reales de planeación de clases con juegos.
4. Recolección y análisis de la información obtenida en las pruebas piloto, identificando fortalezas, limitaciones y oportunidades de mejora tanto en el motor de recomendación como en la interfaz.
5. Realización de ajustes finales al prototipo con base en la retroalimentación recogida y elaboración de recomendaciones para trabajos futuros que profundicen en la validación del sistema.

## 4. Requerimientos del sistema

En coherencia con el Objetivo Específico 3 del anteproyecto, este capítulo consolida la especificación de los requerimientos del prototipo del sistema de recomendación y de su herramienta web. Los requerimientos definen el alcance verificable del desarrollo, orientan las decisiones de diseño e implementación y constituyen la base objetiva para la validación posterior del prototipo. Se presentan en dos categorías: (i) requisitos funcionales (qué debe hacer el sistema) y (ii) requisitos no funcionales (cómo debe comportarse el sistema, en términos de atributos de calidad y restricciones)

### 4.1. Requisitos funcionales (RF) especifican qué debe hacer el sistema: servicios, flujos de trabajo y reglas de negocio visibles para el usuario.

Los requisitos funcionales aprobados se encuentran organizados por módulos y priorizados mediante el esquema MoSCoW (Must/Should/Could) con el fin de delimitar el MVP del prototipo y diferenciar funcionalidades base de extensiones post-validación. En total se especifican 34 requisitos funcionales distribuidos en ocho módulos, con 19 requisitos tipo Must, 9 tipo Should y 6 tipo Could.

Tabla 1 Resumen de requisitos funcionales por módulo (MoSCoW)

Módulo	Código	Must	Should	Could	Total
A - Ingesta y Normalización de Datos	ING	2	1	0	3
B - Caracterización de Contexto	CTX	2	1	0	3
C - Taxonomía de Habilidades	TAX	3	1	1	5
D - Motor de Recomendación	REC	3	1	2	6
E - Explicabilidad y Trazabilidad	EXP	2	1	0	3
F - Interfaz Web	UI	3	3	0	6
G - Retroalimentación y Conocimiento	RETRO	2	1	2	5
H - Administración	ADM	2	0	1	3
TOTAL		19	9	6	34

Tabla 2. Lista de requisitos funcionales (RF)

ID	Prioridad	Módulo	Nombre corto	Descripción (síntesis)
RF-ING-01	Must	A/ING	Importación de catálogo base	Importar y almacenar el dataset de juegos con atributos mínimos (p. ej., nombre, ID BGG, duración, complejidad, rango de jugadores, mecánicas, dependencia de idioma, ranking y disponibilidad)
RF-ING-02	Must	A/ING	Normalización de atributos	Normalizar atributos a escalas y formatos consistentes (duración en minutos, complejidad en escala 1–5, rangos validados, mecánicas controladas, dependencia de idioma en niveles, ranking y disponibilidad)
RF-ING-03	Should	A/ING	Actualización incremental	Permitir la actualización incremental del dataset a partir de cambios en fuentes (BGG y/o catálogo interno) sin reprocesar completamente la base.
RF-CTX-01	Must	B/CTX	Captura de perfil de sesión	Capturar parámetros de la sesión/clase necesarios para la recomendación (objetivo(s) de aprendizaje, tamaño de grupo, tiempo disponible, dependencia de idioma, etc.)
RF-CTX-02	Must	B/CTX	Validación de coherencia	Validar coherencia entre el contexto ingresado y restricciones operativas (p. ej., duración vs. tiempo disponible, min/max jugadores vs. tamaño de grupo) para evitar consultas inconsistentes.
RF-CTX-03	Should	B/CTX	Plantillas reutilizables	Permitir guardar y reutilizar plantillas de contexto frecuentes para reducir tiempos de preparación.
RF-TAX-01	Must	C/TAX	Taxonomía de habilidades	Definir una taxonomía de habilidades y categorías relevantes para el CJEI que soporte el mapeo juego–habilidades–objetivos.
RF-TAX-02	Must	C/TAX	Asignación manual de habilidades	Permitir asignar habilidades primarias y secundarias a juegos del catálogo, registrando dichas asignaciones.
RF-TAX-03	Must	C/TAX	Documentación de criterios	Documentar criterios y decisiones utilizados para asignar habilidades y para futuras extensiones de la taxonomía.
RF-TAX-04	Should	C/TAX	Asistencia NLP	Apoyar la asignación de habilidades mediante análisis de texto (NLP) sobre descripciones de juegos.
RF-TAX-05	Could	C/TAX	Co-ocurrencias de habilidades	Analizar o registrar co-ocurrencias de habilidades para apoyar análisis y mejora continua.
RF-REC-01	Must	D/REC	Generación de Top-N	Generar recomendaciones Top-N combinando filtrado basado en contenido, reglas pedagógicas y contexto de clase.

RF-REC-02	Must	D/REC	Configuración de pesos	Permitir ajustar pesos de componentes del modelo híbrido (contenido/reglas/feedback) para calibración.
RF-REC-03	Must	D/REC	Manejo de restricciones	Gestionar restricciones duras y blandas según condiciones de la sesión (duración, jugadores, idioma, disponibilidad)
RF-REC-04	Should	D/REC	Priorización por feedback	Priorizar o reordenar recomendaciones incorporando retroalimentación de uso registrada.
RF-REC-05	Could	D/REC	Recomendación por semilla	Recomendar juegos similares a partir de un juego “semilla” seleccionado.
RF-REC-06	Could	D/REC	Favoritos y exclusiones	Permitir marcar favoritos y excluir juegos para personalización.
RF-EXP-01	Must	E/EXP	Explicación de recomendaciones	Mostrar explicación de por qué se recomienda un juego (criterios, coincidencias y restricciones aplicadas)
RF-EXP-02	Must	E/EXP	Registro de trazabilidad	Registrar trazas de selección (inputs, reglas aplicadas y resultados) para preservación de conocimiento.
RF-EXP-03	Should	E/EXP	Visualización de rastros	Visualizar rastros de decisión para análisis y mejora continua.
RF-UI-01	Must	F/UI	Autenticación y roles	Gestionar autenticación y roles de usuario para controlar acceso (incluye consideraciones de seguridad básica de acceso)
RF-UI-02	Must	F/UI	Creación de consulta	Permitir crear una consulta de recomendación ingresando contexto de sesión.
RF-UI-03	Must	F/UI	Visualización de recomendaciones	Visualizar lista Top-N con información clave del juego y su explicación asociada.
RF-UI-04	Should	F/UI	Vista detallada del juego	Mostrar ficha detallada de un juego (atributos, habilidades, mecánicas y metadatos relevantes)
RF-UI-05	Should	F/UI	Búsqueda y filtros rápidos	Incorporar búsqueda y filtros para explorar el catálogo y ajustar resultados.
RF-UI-06	Should	F/UI	Identidad visual CJEI	Aplicar lineamientos de identidad visual del CJEI y criterios de accesibilidad/responsividad en la interfaz.
RF-RETRO-01	Must	G/RETRO	Registro de feedback	Registrar retroalimentación de los asesores sobre utilidad/uso de recomendaciones (valoración y observaciones)
RF-RETRO-02	Must	G/RETRO	Visualización de feedback histórico	Visualizar el historial de feedback para consulta y preservación de conocimiento.
RF-RETRO-03	Should	G/RETRO	Análisis de patrones de uso	Analizar patrones de uso del catálogo y de recomendaciones a partir del feedback.
RF-RETRO-04	Could	G/RETRO	Exportación de reportes	Exportar reportes de uso/feedback para documentación y evaluación.

RF-RETRO-05	Could	G/RETRO	Votos en comentarios	Permitir votación en comentarios (up/down) para priorizar retroalimentación de calidad.
RF-ADM-01	Must	H/ADM	Gestión de catálogo	Administrar catálogo (alta/baja/cambios, disponibilidad y atributos) para consolidar repositorio único.
RF-ADM-02	Must	H/ADM	Gestión de taxonomía	Administrar taxonomía (versionado, ajustes y validación) como soporte del modelo juego-habilidades.
RF-ADM-03	Could	H/ADM	Gestión de usuarios	Administrar usuarios y roles (creación, edición, desactivación/reactivación) para escalabilidad operativa.

#### 4.1.1 Criterios de aceptación y dependencias (extracto del MVP)

A continuación se detallan criterios de aceptación explícitos disponibles en el documento de requerimientos aprobado para algunos RF priorizados como Must del MVP. Los demás RF mantienen sus criterios de aceptación en el documento de especificación de requerimientos y se verifican en el plan de validación (Cap. 7)

RF-ING-01 (Importación de catálogo base) – criterios de aceptación:

- Importación correcta de al menos el 95% de los juegos del catálogo CJEI.
- Atributos obligatorios (nombre, ID BGG, disponibilidad) presentes en el 100% de los registros importados.
- Los juegos con atributos incompletos se marcan como “datos parciales” y no generan errores.
- Reporte de importación con totales importados, rechazados y advertencias.

RF-ING-02 (Normalización de atributos) – criterios de aceptación:

- Duración expresada en minutos para el 100% de juegos válidos (rango 5–360)
- Complejidad normalizada en escala 1.0–5.0 para el 100% de juegos válidos.
- Mecánicas normalizadas contra vocabulario controlado (mínimo 50 mecánicas estándar de BGG)
- Valores fuera de rango o formato incorrecto se corrigen automáticamente o se marcan para revisión manual.
- Documentación del diccionario de datos con definición de escalas y formatos.

**4.2. Requisitos no funcionales (RNF) describen cómo debe comportarse el sistema: atributos de calidad (rendimiento, seguridad ergonomía etc) o restricciones tecnológicas y normativas.**

El anteproyecto establece que, además de los RF, el prototipo debe especificar RNF asociados a usabilidad, interpretabilidad de las recomendaciones, rendimiento, disponibilidad y seguridad básica de acceso. En el alcance del documento de requerimientos aprobado, estos RNF se evidencian principalmente a través de criterios de aceptación y restricciones incluidas en requisitos del motor de recomendación, la interfaz web y los módulos de retroalimentación/administración.

Tabla 3 Requisitos no funcionales (RNF) identificados y su verificación.

ID	Categoría	Descripción	Verificación / RF relacionado
RNF-01	Rendimiento	El cálculo de recomendaciones debe completarse en tiempos acotados para soportar el flujo de consulta del asesor.	Criterios de aceptación asociados a RF-REC-01 y RF-UI-03 (tiempos de respuesta)
RNF-02	Usabilidad	La captura de contexto y la exploración de resultados deben ser comprensibles y reducir errores de entrada.	RF-CTX-02 (validación de coherencia) RF-UI-02/05 (interacción)
RNF-03	Accesibilidad / UX	La interfaz debe seguir lineamientos de identidad visual y criterios de accesibilidad y responsividad.	RF-UI-06 (identidad visual, responsividad y accesibilidad)
RNF-04	Interpretabilidad	Las recomendaciones deben ser explicables y trazables para que el asesor comprenda la razón de la sugerencia.	RF-EXP-01 (explicación) y RF-EXP-02/03 (trazabilidad/rastros)
RNF-05	Seguridad básica de acceso	El acceso a la herramienta debe estar controlado por autenticación y roles.	RF-UI-01 (autenticación y roles)
RNF-06	Disponibilidad	El sistema debe estar disponible para el uso por asesores en el entorno de despliegue definido por el proyecto.	Atributo identificado en el anteproyecto; umbrales y acuerdos de disponibilidad se fijan en el plan de despliegue/operación.
RNF-07	Trazabilidad / Auditoría	Las modificaciones de usuarios y elementos críticos deben poder auditarse.	RF-ADM-03 (log de auditoría de cambios de usuarios) y RF-EXP-02 (registro de trazabilidad)

## **5. Análisis y diseño**

### **5.1. Visión del sistema y alcance funcional del prototipo**

El prototipo se concibe como un sistema de recomendación de juegos de mesa para el aprendizaje basado en juegos (Game-Based Learning) en el contexto operativo del Centro de Juegos y Experiencias Interactivas (CJEI). Su finalidad es apoyar al asesor pedagógico en la selección, justificación y documentación de juegos adecuados para una sesión específica, preservando el conocimiento institucional (criterios de selección y experiencias de uso) y reduciendo el tiempo de búsqueda y evaluación manual.

En línea con el anteproyecto, el alcance funcional se centra en: (i) caracterizar juegos mediante atributos lúdicos y operativos (ii) definir un perfil de sesión con objetivos pedagógicos y restricciones (iii) mantener una taxonomía jerárquica de habilidades y asociarla con juegos (iv) generar recomendaciones Top-N bajo restricciones (v) explicar y auditar la recomendación (explicabilidad + trazabilidad) y (vi) registrar retroalimentación post-sesión como evidencia de uso para aprendizaje organizacional.

El repositorio del prototipo declara una implementación integral de un MVP 1.0 que cubre los requisitos priorizados y estructura la solución en módulos funcionales (A a H) desde la ingesta de datos hasta administración y analítica. En consecuencia, este capítulo documenta el análisis y el diseño con base en esas decisiones y su materialización en el prototipo.

### **5.2. Actores, perfiles de usuario y contexto de uso**

El sistema se diseña para un escenario institucional (uso interno) donde el asesor pedagógico gestiona sesiones de aprendizaje con restricciones reales (tiempo, tamaño de grupo, modalidad e idioma). Se identifican los siguientes actores y perfiles de usuario:

- Asesor pedagógico (rol operativo): crea perfiles de sesión, selecciona habilidades objetivo, solicita recomendaciones, consulta explicaciones, compara alternativas, selecciona un juego y registra retroalimentación posterior.
- Administrador/a del sistema (rol de gobierno): gestiona el catálogo (altas/bajas/edición, disponibilidad) administra la taxonomía (CRUD jerárquico) configura pesos del motor de recomendación, consulta auditoría y analíticas.

- Fuente de datos externa (actor no humano): origen de datos para incorporación/actualización del catálogo mediante importación masiva (por ejemplo, CSV/JSON)
- Equipo académico/investigador (actor de soporte): analiza resultados, trazabilidad y patrones para iterar el prototipo y sustentar evaluación del trabajo de grado.

La segregación de funciones se implementa mediante control de acceso por roles (RBAC) y flujos diferenciados: el asesor se orienta a recomendación, explicación y feedback; el administrador se orienta a mantenimiento del conocimiento (catálogo y taxonomía) y gobierno del sistema (configuración/auditoría)

### 5.3. Casos de uso y flujos de interacción

Los casos de uso se derivan de los requerimientos funcionales del sistema y se organizan alrededor del ciclo de una sesión. El flujo principal es: autenticación → creación de perfil de sesión → selección de habilidades/objetivos → generación de recomendaciones Top-N → consulta de explicación y trazabilidad → selección del juego → registro de retroalimentación post-sesión. La Tabla 4 sintetiza los casos de uso principales y los módulos involucrados.

Tabla 4. *Casos de uso principales del prototipo.*

ID	Nombre	Actor principal	Módulo(s)	Descripción / datos clave
UC-01	Autenticarse y gestionar sesión de usuario	Asesor / Admin	F	Inicio de sesión; acceso según rol.
UC-02	Crear perfil de sesión (contexto de clase)	Asesor	B	Objetivos; habilidad primaria y secundarias; restricciones (tiempo, jugadores, modalidad, idioma)
UC-03	Validar coherencia del perfil de sesión	Asesor	B	Warnings no bloqueantes ante riesgos (p. ej., grupo grande o tiempo muy limitado)
UC-04	Solicitar recomendaciones Top-N	Asesor	D	Filtros duros + scoring híbrido; Top-N configurable; manejo de cero resultados.
UC-05	Consultar explicación y trazabilidad	Asesor	E	Razones específicas por recomendación; snapshots inmutables; comparación 2-5 alternativas.
UC-06	Seleccionar juego recomendado	Asesor	D/E/F	Marca de selección; vínculo a retroalimentación.
UC-07	Registrar retroalimentación post-sesión	Asesor	G	Uso/no uso, utilidad 1-5, comentarios cualitativos, habilidad realmente trabajada.
UC-08	Importar/actualizar juegos (masivo)	Admin	A	Importación CSV/JSON; validación; estrategias update/skip/replace.
UC-09	Administrar catálogo y disponibilidad	Admin	H	Dashboard de catálogo; control de disponibilidad; estadísticas.

UC-10	Administrar taxonomía y asociaciones	Admin	C/H	CRUD jerárquico; asociación juego-habilidad con justificación.
UC-11	Configurar pesos del scoring	Admin	D	Crear/activar configuraciones; validación de pesos; auditoría de configuración usada.
UC-12	Consultar analíticas y patrones	Admin	G/H	Analíticas de uso; joyas ocultas; candidatos a revisión; distribución por habilidad.

#### 5.4. Arquitectura lógica del prototipo

La arquitectura lógica se implementa como solución web full-stack con tres capas: (i) frontend web para interacción por tareas (ii) backend API para reglas de negocio, motor de recomendación, explicabilidad y servicios de administración, y (iii) base de datos relacional para persistencia de catálogo, taxonomía, perfiles de sesión, recomendaciones, trazabilidad y retroalimentación.

El prototipo documenta el uso de un backend en Python (FastAPI) y un frontend en React (TypeScript) con PostgreSQL como base de datos. Se incorpora una estrategia de despliegue reproducible mediante Docker, así como migraciones de esquema (Alembic) y modelos ORM (SQLAlchemy) El diseño también contempla autenticación (tokens) y un esquema de pruebas automatizadas para validar requisitos críticos.

A nivel de componentes, la lógica se organiza por módulos funcionales: A (Ingesta) B (Contexto de sesión) C (Taxonomía) D (Recomendación) E (Explicabilidad y trazabilidad) F (UI) G (Retroalimentación) y H (Administración) Esta modularidad facilita trazabilidad de requisitos, pruebas por componente y evolución incremental.

#### 5.5. Modelo de información y fuentes de datos

El modelo de información se diseña para capturar (a) el conocimiento del catálogo de juegos (atributos y disponibilidad) (b) el conocimiento pedagógico (taxonomía jerárquica de habilidades y justificaciones) (c) el contexto de ejecución (perfil de sesión) y (d) la evidencia de decisión y uso (recomendaciones, trazabilidad y feedback)

Dominios principales:

- Catálogo de juegos: nombre/identificador, mecánicas, categorías, complejidad (escala) duración, número de jugadores, dependencia de idioma, modalidad, disponibilidad y metadatos de calidad (p. ej., ranking externo cuando exista)

- Taxonomía de habilidades: estructura jerárquica de cuatro niveles con categorías macro y habilidades específicas; permite estados (activa/inactiva) y administración por rol.
- Asociación juego-habilidad: relación many-to-many con “justificación pedagógica” para sostener explicabilidad y gobierno del conocimiento.
- Perfil de sesión: objetivos pedagógicos en texto, habilidad primaria, habilidades secundarias, restricciones operativas (tiempo, jugadores, idioma, modalidad) y notas contextuales.
- Recomendación y trazabilidad: vínculo sesión-juego + desglose de scoring, razones, warnings y snapshots inmutables del contexto, estado del juego y configuración del motor.
- Retroalimentación: campos cuantitativos (uso, score 1-5) y cualitativos (qué funcionó, qué no, notas) asociados a la recomendación seleccionada.

Fuentes de datos: el prototipo contempla importación masiva (CSV/JSON) como mecanismo de ingesta/actualización del catálogo y carga semilla para pruebas. En la documentación del repositorio se declara una base inicial de aproximadamente 950 juegos para el MVP, lo que exige normalización consistente de atributos y relaciones para soportar filtrado y scoring.

## 5.6. Taxonomía pedagógica y representación de objetivos de aprendizaje

La taxonomía pedagógica es el eje de alineación entre objetivos educativos y juegos de mesa. Constituye el núcleo semántico del sistema de recomendación, estableciendo un puente estructurado y verificable entre los juegos del catálogo, las habilidades que desarrollan y los objetivos de aprendizaje de las sesiones.

### 5.6.1. Propósito y fundamento teórico

La taxonomía sirve múltiples propósitos institucionales:

- **Recomendación informada:** Permite al sistema sugerir juegos cuyas mecánicas y contenido se alineen con las habilidades objetivo
- **Trazabilidad pedagógica:** Documenta formalmente por qué un juego es apropiado para desarrollar ciertas habilidades
- **Comunicación interdisciplinaria:** Establece un vocabulario común entre asesores pedagógicos y docentes

- **Base para investigación:** Proporciona un marco conceptual replicable para futuros estudios
- **Mejora continua:** Facilita evaluación post-sesión comparando habilidades objetivo vs. habilidades trabajadas

La taxonomía se fundamenta en marcos pedagógicos consolidados:

- **Taxonomía de Bloom [39]:** Estructura jerárquica para habilidades cognitivas
- **Teoría del Aprendizaje Social de Bandura [41]:** Fundamenta habilidades sociales y de colaboración
- **Inteligencias Múltiples de Gardner [46]:** Reconoce diversidad de capacidades
- **Competencias del Siglo XXI (P21) [47]:** Incorpora pensamiento crítico, comunicación, colaboración y creatividad

### 5.6.2. Estructura jerárquica implementada

La taxonomía se organiza en tres niveles de especificidad creciente:

Nivel	Descripción	Cantidad
Nivel 1: Dominio	Grandes áreas de desarrollo (Cognitivo, Social, Emocional, Práctico)	4
Nivel 2: Categoría	Agrupaciones temáticas (Pensamiento Estratégico, Comunicación, etc.)	11
Nivel 3: Habilidad Específica	Habilidades concretas y observables	25
TOTAL	Nodos en la taxonomía	40

### 5.6.3. Los cuatro dominios de habilidades

**Dominio Cognitivo (ID: 1):** Capacidades mentales y de pensamiento. Incluye 4 categorías: Pensamiento Estratégico (Planificación, Toma de decisiones, Análisis de riesgos), Pensamiento Crítico (Razonamiento lógico, Resolución de problemas, Análisis

de información), Creatividad (Innovación, Pensamiento divergente, Imaginación) y Memoria. Total: 10 habilidades específicas (27.8% de la taxonomía).

**Dominio Social (ID: 2):** Capacidades de interacción y relación con otros. Incluye 4 categorías: Trabajo en equipo (Cooperación, Coordinación, Construcción de consenso), Comunicación (Comunicación verbal, Comunicación no verbal, Escucha activa), Liderazgo (Motivación de equipos, Delegación, Toma de iniciativa) y Negociación. Total: 13 habilidades específicas (36.1% de la taxonomía).

**Dominio Emocional (ID: 3):** Capacidades de gestión emocional y bienestar. Incluye 3 categorías: Inteligencia emocional (Autoconocimiento, Autorregulación, Motivación intrínseca), Resiliencia y Empatía. Total: 6 habilidades específicas (16.7% de la taxonomía).

**Dominio Práctico (ID: 4):** Capacidades de ejecución y acción. Incluye: Gestión de recursos, Gestión del tiempo, Adaptabilidad y Perseverancia. Total: 4 habilidades específicas (11.1% de la taxonomía).

#### 5.6.4. Modelo de asociación juego-habilidad

Cada juego del catálogo se asocia con habilidades mediante un modelo de relación many-to-many que incluye justificación pedagógica obligatoria. La asociación documenta:

- **Mecánica relevante:** Qué mecánica específica del juego ejercita la habilidad
- **Dinámica de juego:** Cómo la interacción durante partidas activa la habilidad
- **Contexto de aprendizaje:** Bajo qué condiciones se maximiza el desarrollo

**Estado actual del MVP:** 22 juegos en catálogo, 8 juegos con asociaciones documentadas (36.4%), 41 asociaciones juego-habilidad registradas, promedio de 5.1 habilidades por juego documentado.

#### 5.6.5. Ejemplos de asociaciones documentadas

**Pandemic:** Asociado con 5 habilidades. Cooperación: "Es un juego completamente cooperativo donde todos ganan o pierden juntos". Trabajo en equipo: "Requiere colaboración constante y comunicación entre jugadores". Planificación: "Necesita planificación estratégica para contener epidemias y encontrar curas". Toma de decisiones:

"Decisiones críticas sobre prioridades y uso óptimo de acciones limitadas". Resolución de problemas: "Enfrentar situaciones complejas y encontrar soluciones creativas".

**Dixit:** Asociado con 5 habilidades. Creatividad: "Requiere pensamiento creativo para dar pistas ambiguas pero comprensibles". Comunicación: "La comunicación indirecta y sutil es fundamental para el éxito". Imaginación: "Necesita imaginación para interpretar las ilustraciones abstractas". Empatía: "Debe ponerse en el lugar de otros para entender sus perspectivas". Pensamiento divergente: "Buscar múltiples interpretaciones y conexiones no obvias".

**Catan:** Asociado con 4 habilidades. Negociación: "Requiere negociar constantemente recursos con otros jugadores para avanzar en el juego". Planificación: "Los jugadores deben planificar estratégicamente la ubicación de asentamientos y expansión". Toma de decisiones: "Decisiones continuas sobre dónde construir y qué recursos intercambiar". Trabajo en equipo: "Aunque competitivo, promueve interacción social y negociación entre jugadores".

#### 5.6.6. Representación de objetivos de aprendizaje

El sistema combina dos mecanismos complementarios para capturar intención pedagógica:

**Objetivos en texto libre:** Permiten registrar el propósito de la sesión en lenguaje natural para documentación y consulta.

**Habilidad primaria y secundarias (estructurado):** Selección de nodos de la taxonomía que alimentan el motor de recomendación y habilitan trazabilidad formal. La habilidad primaria es obligatoria y constituye el criterio principal para el scoring. Las habilidades secundarias son opcionales y contribuyen con peso menor.

Este mapeo permite trazabilidad completa: se puede explicar por qué un juego se recomendó para un objetivo específico, garantizar consistencia en recomendaciones similares y validar o refinar asociaciones mediante feedback post-sesión.

#### 5.6.7. Integración con el motor de recomendación

La taxonomía se integra directamente con el componente de Skill Score del motor de recomendación híbrido (40% del scoring total). El algoritmo busca juegos cuyas habilidades asociadas coincidan con las habilidades objetivo de la sesión:

$$\text{SkillScore} = (\text{PrimaryMatch} \times 1.0) + (\text{SecondaryMatch} \times 0.5) + \text{ComplexityAlignment}$$

Donde PrimaryMatch es el número de habilidades primarias del juego que coinciden con habilidades objetivo, SecondaryMatch es el número de habilidades secundarias que coinciden, y ComplexityAlignment es una bonificación/penalización por alineación de complejidad del juego con el nivel de la habilidad.

El sistema genera explicaciones basadas en las justificaciones pedagógicas almacenadas, mostrando al asesor por qué cada juego fue recomendado y qué habilidades adicionales desarrolla más allá de las solicitadas.

#### 5.6.8. Gobernanza y versionado

La taxonomía utiliza versionado semántico (MAJOR.MINOR.PATCH) para mantener trazabilidad histórica. La versión actual es v1.0.0 (enero 2026) con 40 nodos totales. El sistema mantiene snapshots de cada versión para garantizar que las recomendaciones antiguas puedan auditarse con la taxonomía vigente en su momento.

Se ha establecido un proceso formal para incorporación de nuevas habilidades que incluye propuesta con justificación, validación de unicidad y observabilidad, aprobación por consenso de asesores, y documentación de al menos tres asociaciones con juegos antes de considerar la habilidad como estable.

La calidad de las asociaciones se monitorea mediante indicadores: cobertura del catálogo (meta 100%, actual 36.4%), promedio de habilidades por juego (meta 3-5, actual 5.1), y porcentaje de asociaciones con justificación pedagógica completa (actual 95.1%). La retroalimentación post-sesión captura habilidades realmente trabajadas, permitiendo validar y refinar asociaciones según experiencia de campo.

### 5.7. Diseño del motor de recomendación

El motor de recomendación se diseña como un pipeline determinístico y trazable: primero aplica filtros duros (viabilidad) y luego ordena candidatos mediante scoring híbrido (pertinencia). El objetivo del pipeline es producir un Top-N (por defecto, Top-5) con explicaciones específicas y auditables.

Capa 1 - Filtrado duro (hard filters):

- Disponibilidad: excluye juegos marcados como no disponibles.
- Jugadores: valida que el grupo esté dentro del rango mínimo/máximo del juego.
- Tiempo: valida ventana de duración; el prototipo documenta una tolerancia del 20% para ampliar el conjunto de candidatos sin perder coherencia operativa.
- Idioma: filtra por dependencia de idioma (especialmente relevante en grupos con diversidad lingüística)

Capa 2 - Scoring híbrido (ordenamiento):

El prototipo documenta un esquema con cuatro componentes ponderados: (i) alineación pedagógica (habilidades y complejidad) (ii) similitud por mecánicas (incluyendo modalidad) (iii) ajuste por restricciones (tiempo y grupo) y (iv) un indicador de calidad (p. ej., ranking) cuando se disponga. La configuración de pesos es parametrizable (suma de pesos = 100%) y se conserva en cada recomendación para auditoría.

Manejo de cero resultados: el motor retorna diagnóstico de causas y sugerencias para relajar restricciones, evitando que el sistema “falle silenciosamente”. Esta decisión de diseño es clave para usabilidad institucional, donde el asesor requiere alternativas accionables ante catálogos limitados.

### **5.8. Procesamiento semántico (NLP) y enriquecimiento de información**

El anteproyecto y los requerimientos incluyen la necesidad de apoyar la clasificación pedagógica mediante asistencia semántica (NLP) para sugerir habilidades. En el diseño, este componente opera como asistente y no como decisor: propone habilidades candidatas a partir de texto libre (objetivos de sesión o descripciones) pero la confirmación final es humana (asesor o administrador) garantizando gobernanza pedagógica.

Diseño propuesto del pipeline NLP (asistencia):

- Normalización y limpieza: minúsculas, eliminación de signos, stopwords y normalización de acentos.
- Extracción de señales: términos clave y n-gramas; detección de términos del diccionario pedagógico.
- Correspondencia y scoring: asignación de candidatos por coincidencia y/o similitud semántica.

- Trazabilidad: registro de la evidencia textual que soporta la sugerencia (términos activadores) para que la recomendación de habilidades sea explicable.

Nota de alcance: cuando este componente no se implementa en el MVP, se documenta como línea de evolución, preservando coherencia con el alcance y evitando afirmar capacidades no presentes.

### **5.9. Diseño de explicabilidad y trazabilidad de recomendaciones**

La explicabilidad se implementa como una capa derivada del pipeline de recomendación. Su objetivo es traducir filtros y scoring a razones comprensibles para el asesor. La documentación del prototipo afirma que cada recomendación incluye al menos 4 razones específicas, además de warnings contextuales cuando aplique.

La trazabilidad se diseña como auditoría completa e inmutable por recomendación, incluyendo:

- Snapshot del perfil de sesión (objetivos, restricciones y grupo)
- Snapshot del estado del juego (nombre, mecánicas, complejidad, disponibilidad)
- Configuración de scoring utilizada (pesos vigentes en el momento de cálculo)
- Rationale completo (desglose de decisión) y resultado del feedback posterior.
- Histórico por sesión (batches de recomendaciones) y comparación lado a lado (2-5 recomendaciones)

El diseño incluye un endpoint dedicado para informes completos de trazabilidad y mecanismos de comparación para soportar la toma de decisión del asesor y el análisis posterior por el equipo académico.

### **5.10. Diseño de la interfaz de usuario (UI/UX)**

La interfaz se diseña por flujos y tareas, minimizando la fricción del asesor. Para el rol operativo se contemplan, al menos: (i) autenticación (ii) formulario de creación/edición del perfil de sesión (iii) selección de habilidades y restricciones (iv) vista de recomendaciones Top-N con indicadores clave (v) detalle de juego con explicación y trazabilidad, y (vi) formulario de retroalimentación post-sesión.

Para el rol administrador, se incorporan vistas de gobierno: dashboard de catálogo (disponibles/no disponibles, distribuciones por complejidad y jugadores, juegos más recomendados) gestión de taxonomía (CRUD y navegación jerárquica) y analíticas de uso/feedback. El diseño privilegia

validaciones tempranas y mensajes claros para evitar estados inconsistentes (por ejemplo, restricciones incompatibles que producirían cero resultados)

### 5.11. Reglas de negocio y validaciones

Las reglas de negocio se derivan de los requerimientos aprobados y de las decisiones implementadas en el prototipo. Las validaciones se aplican de forma autoritativa en backend y de forma preventiva en frontend. Entre las reglas clave se incluyen:

- Importación masiva: validación de esquema; control de calidad (umbral máximo de registros inválidos) y estrategias de actualización (update/skip/replace)
- Perfil de sesión: obligatoriedad de habilidad primaria; restricciones de longitud para textos; warnings cuando el perfil tiene alta probabilidad de producir recomendaciones pobres (tiempo excesivamente corto o grupo muy grande)
- Scoring: suma de pesos = 100% y una única configuración activa; conservación de la configuración usada en cada recomendación.
- Recomendación: aplicación obligatoria de filtros duros; tolerancia temporal documentada; diagnóstico explícito en caso de cero resultados.
- Feedback: campos obligatorios (uso/no uso, score 1-5, asesor) y campos opcionales con límites de longitud; ventana de edición documentada (7 días) para mantener integridad.

### 5.12. Trazabilidad Requerimientos - Diseño

Para asegurar alineación entre necesidad (requerimientos) y solución (diseño) se construye una matriz de trazabilidad que mapea cada requisito funcional a: (i) módulo funcional (ii) artefactos lógicos (servicios y vistas) y (iii) dominios de datos impactados. Esta matriz controla alcance (evita scope creep) y estructura la validación y los resultados del capítulo 7.

Tabla 5. *Matriz de trazabilidad Requerimientos - Diseño (resumen)*

RF	Módulo	Artefacto de diseño (lógico)	Datos afectados (alto nivel)
RF-ING-01 / RF-ING-02 / RF-ING-03	A	Servicio de ingesta/normalización + importación masiva	Juegos, mecánicas, categorías, disponibilidad
RF-CTX-01 / RF-CTX-02	B	Perfil de sesión + validación con warnings	Sesiones, objetivos, habilidades, restricciones
RF-TAX-01 / RF-TAX-02 / RF-TAX-03	C	Taxonomía jerárquica + asociación juego-habilidad	Habilidades, jerarquía, justificaciones

RF-REC-01 / RF-REC-02 / RF-REC-03	D	Filtros duros + scoring híbrido + configuración de pesos	Recomendaciones, configuraciones, scoring
RF-EXP-01 / RF-EXP-02	E	Explicación + auditoría/snapshots + comparación	Trazabilidad, snapshots, reportes
RF-UI-01 / RF-UI-02 / RF-UI-03	F	UI por flujos + autenticación + vistas principales	Usuarios (rol) sesiones, recomendaciones
RF-RETRO-01 / RF-RETRO-02 / RF-RETRO-03	G	Registro de feedback + estadísticas/analíticas	Feedback, agregados, patrones
RF-ADM-01 / RF-ADM-02	H	Dashboard administrativo + gestión de catálogo/taxonomía	Catálogo, taxonomía, auditoría

## 6. IMPLEMENTACIÓN

Este capítulo describe la materialización técnica del prototipo del Sistema de Recomendación de Juegos de Mesa para el Centro de Juegos y Experiencias Interactivas (CJEI) a partir del repositorio de desarrollo del MVP y su documentación técnica. Se presentan el alcance implementado, el entorno, la construcción de la base de datos, la implementación del modelo de información, el motor de recomendación y sus componentes asociados, la interfaz web, la integración extremo a extremo y la verificación técnica interna.

### 6.1. Alcance de la implementación y criterios de completitud del prototipo

La implementación corresponde al MVP 1.0 del prototipo, concebido como un sistema end-to-end operacional con backend y frontend integrados. El criterio principal de completitud se define por la cobertura total de los requerimientos MUST contemplados para el MVP, reportándose 19/19 requerimientos MUST implementados (100%) así como la operación completa de los módulos funcionales A–H y la disponibilidad de documentación de uso y pruebas automatizadas. En el repositorio se reportan los siguientes módulos implementados:

- Módulo A – Ingesta y Normalización (RF-ING-01, RF-ING-02, RF-ING-03)
- Módulo B – Contexto de Clase (RF-CTX-01, RF-CTX-02)
- Módulo C – Taxonomía de Habilidades (RF-TAX-01, RF-TAX-02, RF-TAX-03)
- Módulo D – Motor de Recomendación (RF-REC-01, RF-REC-02, RF-REC-03)
- Módulo E – Explicabilidad y Trazabilidad (RF-EXP-01, RF-EXP-02)
- Módulo F – Interfaz Web (RF-UI-01, RF-UI-02, RF-UI-03)
- Módulo G – Retroalimentación (RF-RETRO-01, RF-RETRO-02, RF-RETRO-03)
- Módulo H – Administración (RF-ADM-01, RF-ADM-02)

Como criterio complementario de completitud, la implementación incluye: (i) migraciones de base de datos (8 migraciones reportadas) (ii) scripts de inicialización/seed para datos de prueba (iii) endpoints de API (62+ endpoints operacionales reportados) y (iv) batería de pruebas backend (63+ pruebas y escenarios E2E)

## 6.2. Entorno de desarrollo y dependencias del proyecto

El prototipo se implementa bajo una arquitectura cliente-servidor con dos componentes principales: (a) un backend expuesto como API REST y (b) un frontend web para asesores pedagógicos. El stack tecnológico reportado contempla Python 3.11+ y PostgreSQL 14+ para el backend, y Node.js 18+ con React + TypeScript para el frontend.

Tabla 6. Stack tecnológico

Componente	Tecnologías/Versiones reportadas	Rol en el prototipo
Backend	FastAPI 0.104+ (Python 3.11+) SQLAlchemy 2.0, Pydantic v2, Alembic, Pytest, JWT (python-jose)	API REST, reglas de negocio, recomendación, explicabilidad, persistencia
Base de datos	PostgreSQL 14+	Persistencia del catálogo, taxonomía, sesiones, recomendaciones, trazas y feedback
Frontend	React 19.2.0 + TypeScript 5.9.3, Vite 7.2.4, TanStack React Query 5.90.16, React Hook Form 7.70.0 + Zod 4.3.5, React Router 7.11.0, Tailwind CSS 4.1.18, Axios 1.13.2, Lucide React 0.562.0	Interfaz web para creación de sesiones, visualización de recomendaciones y captura de feedback

Para la ejecución local, la documentación del repositorio establece la creación de un entorno virtual Python, la instalación de dependencias mediante requirements.txt, la configuración de variables de entorno (.env) y el levantamiento del servidor FastAPI con Uvicorn. De forma análoga, en el frontend se instala la dependencia mediante npm y se ejecuta el servidor de desarrollo con Vite.

### Comandos de referencia para levantar el prototipo en entorno local:

```
#Backend (terminal1)
cd backend
python3.11 -m venv venv
source venv/bin/activate # Windows: venv\Scripts\activate
pip install -r requirements.txt
cp .env.example .env # Configurar DATABASE_URL, SECRET_KEY
createdb cjei_recommendations
alembic upgrade head
python -m scripts.seed_data
uvicorn app.main:app --reload --port 8000

# Frontend (terminal 2)
cd frontend
npm install
```

```
cp .env.example .env # VITE_API_BASE_URL -> http://localhost:8000
npm run dev
```

### 1.1.1. URLs de acceso reportadas para el entorno local:

- Frontend: <http://localhost:5173>
- Backend API: <http://localhost:8000>
- Documentación API (Swagger): <http://localhost:8000/docs>
- ReDoc: <http://localhost:8000/redoc>

## 6.3. Construcción de la base de datos y preparación de fuentes de información

La persistencia del prototipo se soporta en PostgreSQL. El repositorio describe un flujo de inicialización que incluye la creación de la base de datos, la ejecución de migraciones con Alembic (8 migraciones) y la carga de datos semilla mediante un script de seed. Este proceso permite disponer de un conjunto mínimo de datos de prueba para validar el flujo extremo a extremo del sistema.

Flujo de inicialización de base de datos (según documentación del repositorio):

```
createdb cjei_recommendations
alembic upgrade head
python -m scripts.seed_data
```

La preparación de fuentes de información se apoya en archivos de ejemplo ubicados en el repositorio (p. ej., carpeta `sample_data`) y en mecanismos de importación masiva (CSV/JSON) disponibles en la API para poblar el catálogo de juegos. Como estado del MVP, se reporta un conjunto de datos inicial compuesto por 8 juegos, 40 habilidades y 3 configuraciones de scoring, suficiente para pruebas funcionales y demostraciones.

## 6.4. Implementación del modelo de información (persistencia)

El modelo de información se implementa en el backend mediante modelos ORM con SQLAlchemy y esquemas de validación con Pydantic. La evolución del esquema se gestiona con Alembic, registrándose 8 migraciones. En la estructura del backend se reportan 6 modelos principales y módulos separados por dominios funcionales (`games`, `sessions`, `skills`, `recommendations`, `feedback`, `admin`) lo que favorece la cohesión y la mantenibilidad del prototipo.

A nivel de persistencia, el prototipo contempla entidades para: (i) catálogo de juegos y sus atributos (duración, complejidad, jugadores, idioma, mecánicas) (ii) taxonomía jerárquica de habilidades con asociación many-to-many juego–habilidad y justificación pedagógica (iii) perfiles de sesión con objetivos y restricciones (iv) recomendaciones generadas y su evidencia (scores, razones, configuración utilizada) y (v) feedback post-sesión con atributos cuantitativos y cualitativos.

## 6.5. Implementación del motor de recomendación

El motor de recomendación corresponde al Módulo D y se orienta a producir recomendaciones rankeadas de juegos para un contexto de clase, a partir de un perfil de sesión. La documentación reporta la aplicación de filtros duros (disponibilidad, número de jugadores, tiempo con tolerancia  $\pm 20\%$  e idioma) como paso de preselección de candidatos, seguido por un scoring híbrido de cuatro componentes con pesos configurables.

Componentes de scoring híbrido reportados:

- Skill Score (40%): alineación entre habilidades objetivo/complejidad del juego.
- Mechanics Score (30%): similitud tipo Jaccard entre mecánicas, con bonificación por modalidad.
- Difficulty Score (20%): ajuste por tiempo y tamaño del grupo.
- Ranking Score (10%): normalización de ranking (BGG rank) como indicador de calidad/aceptación.

El motor soporta un parámetro Top-N configurable (1–50) Para controlar la sensibilidad del ranking, se implementa un modelo de configuración de scoring (`ScoringConfig`) con validación de consistencia (la suma de pesos debe ser 1.0 con tolerancia  $\pm 0.001$ ) y un mecanismo de activación única para garantizar que una configuración vigente sea la usada en la generación de recomendaciones.

En escenarios sin candidatos o con restricciones incompatibles, el prototipo implementa manejo explícito de cero resultados mediante análisis de causas (p. ej., grupo muy grande, tiempo insuficiente o idioma) y generación de sugerencias de relajación de restricciones; el resultado se entrega de forma estructurada con un indicador `has_results`.

## 6.6. Implementación de explicabilidad y trazabilidad

La explicabilidad y la trazabilidad se implementan como Módulo E. Para explicabilidad, el sistema genera explicaciones en lenguaje natural con estructura mínima de razones específicas por recomendación (alineación de habilidades, restricciones operacionales, relevancia de mecánicas e indicadores de calidad) La documentación reporta un servicio dedicado (`ExplainabilityService`) con 4 endpoints y la incorporación de advertencias en casos de borde (por ejemplo, complejidad alta o desajuste temporal) así como el desglose del scoring por componente.

Para trazabilidad, el prototipo registra un audit trail completo e inmutable por recomendación. Este mecanismo captura snapshots del perfil de sesión, el estado del juego, la configuración de scoring utilizada, el rationale de decisión y, cuando existe, el resultado de feedback. Adicionalmente, se reporta la capacidad de agrupar recomendaciones por lotes asociados a una sesión y la comparación lado a lado de 2–5 recomendaciones, además de un endpoint específico (`/traceability/{id}`) para informes completos.

## 6.7. Implementación de la interfaz de usuario (UI)

La interfaz web se implementa como Módulo F bajo React + TypeScript y opera como cliente del backend. La UI está orientada a asesores pedagógicos e implementa el flujo principal de trabajo: creación de sesión, generación y visualización de recomendaciones, y captura de retroalimentación posterior. La documentación reporta validación en tiempo real del formulario de sesión mediante Zod, manejo de advertencias no bloqueantes y presentación de recomendaciones en formato de tarjetas expandibles con información operacional y desglose de scores.

### Páginas principales reportadas en la UI:

- / (Home)
- /sessions/new (crear sesión)
- /recommendations/:sessionId (ver recomendaciones)
- /games (catálogo de juegos)
- /skills (taxonomía de habilidades)
- /login (autenticación: pendiente)

En términos de componentes, se reporta un conjunto de 16 componentes reutilizables, incluyendo formularios (`SessionProfileForm`) tarjetas de recomendación (`RecommendationCard`) y

formularios/modales de feedback (`FeedbackForm`) además de componentes de catálogo, taxonomía y utilidades (carga, alertas y confirmaciones)

## 6.8. Integración de componentes y flujo extremo a extremo

La integración se realiza mediante consumo de la API REST del backend desde el frontend, usando un cliente HTTP en el navegador. El repositorio reporta un despliegue local con el backend en el puerto 8000 y el frontend en el puerto 5173, con documentación de endpoints disponible en Swagger. La integración extremo a extremo se materializa en un flujo secuencial: (1) el asesor crea un perfil de sesión con objetivos y restricciones (2) el backend valida el contexto operacional y la taxonomía seleccionada (3) se ejecuta el motor de recomendación para producir un ranking Top-N (4) se genera una explicación y se almacena la trazabilidad, y (5) el asesor registra feedback del juego usado, que queda asociado a la recomendación para análisis posterior.

### Flujo extremo a extremo (resumen operacional):

- Entrada: perfil de sesión (objetivos, habilidades, restricciones operacionales)
- Proceso: filtrado de candidatos + scoring híbrido + explicación + persistencia de trazas.
- Salida: lista rankeada de recomendaciones con desglose de scores y razones.
- Retroalimentación: registro de uso y valoración (1–5) con campos cualitativos.

## 6.9. Verificación técnica interna de la implementación

La verificación técnica interna se apoya en pruebas automatizadas y escenarios E2E reportados para el backend. Se indica la existencia de 63+ pruebas implementadas, incluyendo pruebas por módulo y pruebas de flujo completo end-to-end. Como evidencia de verificación, se reportan resultados de cobertura por módulos, tasa de éxito en escenarios E2E y un reporte detallado disponible en el repositorio.

### 1.1.2. Comandos de ejecución de pruebas backend reportados:

```
cd backend
python tests/test_e2e_complete_flow.py
cat tests/E2E_TEST_REPORT.md
pytest -v
pytest --cov=app --cov-report=html
pytest tests/test_games.py -v
pytest tests/test_sessions.py -v
```

```
pytest tests/test_skills.py -v
pytest tests/test_module_d_integration.py -v
pytest tests/test_module_e_explainability.py -v
python tests/test_recommendations_with_realistic_data.py
```

### **Escenarios E2E reportados como validados:**

- Small Cooperative Session (4 estudiantes, 60 min)
- Large Competitive Session (8 estudiantes, 30 min)
- Time-Constrained Session (3 estudiantes, 20 min) con manejo de cero resultados y sugerencias.
- No Results Handling (100 estudiantes, 15 min) para validación de RF-REC-03.
- Skill-Based Recommendations (integración con taxonomía)

En el frontend, la documentación indica verificación de tipos TypeScript sin errores y build exitoso; las pruebas unitarias del frontend se reportan como pendientes de implementación completa, aunque se consignan comandos de referencia (npm test, cobertura, type-check y lint)

## 7. PLAN DE VALIDACIÓN Y RESULTADOS

Este capítulo presenta el plan de validación del prototipo del Sistema de Recomendación de Juegos de Mesa para el Centro de Juegos y Experiencias Interactivas (CJEI) así como los resultados disponibles a la fecha derivados de la verificación técnica interna y de las pruebas de integración reportadas por el repositorio del proyecto. La validación se estructura para comprobar, de forma trazable y replicable, que el prototipo cumple los requerimientos funcionales priorizados, que mantiene coherencia y consistencia en las recomendaciones, y que aporta valor operativo al proceso de preparación de sesiones por parte de asesores pedagógicos, preservando el conocimiento institucional mediante trazabilidad, explicaciones y retroalimentación.

Dado que la validación con usuarios reales (asesores) se ejecuta mediante un piloto controlado, el presente capítulo diferencia explícitamente entre: (i) resultados ya evidenciados mediante pruebas técnicas y de integración; y (ii) resultados que dependen de trabajo de campo (usabilidad, utilidad percibida, reducción de tiempos) y que se reportarán una vez culminen las sesiones de piloto. Para evitar inferencias no soportadas, los resultados no disponibles aún se documentan como “pendientes” junto con su protocolo de medición y sus formatos de recolección.

### 7.1. Plan de Validación

#### Propósito y alcance de la validación

El propósito de la validación es obtener evidencia suficiente para sustentar que el prototipo: (a) opera de extremo a extremo (ingesta → caracterización de sesión → recomendación → explicabilidad/trazabilidad → selección/retroalimentación → administración); (b) produce recomendaciones consistentes con el perfil y restricciones de la sesión; (c) incorpora mecanismos de trazabilidad que preservan conocimiento institucional; y (d) resulta usable y útil para el rol de asesor pedagógico en el contexto de uso previsto. En términos de investigación, la validación se alinea con el objetivo específico orientado a comprobar la calidad del prototipo y con la pregunta de investigación asociada a la capacidad del sistema de apoyar la recomendación de juegos de mesa bajo un enfoque de aprendizaje basado en juegos.

El alcance se delimita al MVP 1.0 del repositorio, que declara la implementación completa de 19/19 requerimientos MUST (100%) y un sistema end-to-end operacional listo para demostración y pruebas con usuarios reales. Se validan tanto los componentes del backend (API FastAPI y

servicios de recomendación/explicación) como los del frontend (interfaz web React/TypeScript) incluyendo la persistencia en PostgreSQL y el uso de datos semilla para catálogo, taxonomía y configuraciones.

### Dimensiones de evaluación e indicadores (matriz de métricas)

La evaluación se operacionaliza mediante una matriz de métricas que vincula cada dimensión con indicadores observables, métodos de cálculo, instrumentos y criterios de aceptación. La matriz permite el tratamiento posterior de datos y la comparabilidad entre sesiones de piloto. Cuando un indicador requiere medición previa y posterior (por ejemplo, tiempos de preparación) se define el diseño de medición “antes/después” con el mismo participante y tareas equivalentes.

Tabla 7. Matriz de métricas

Dimensión	Indicador	Definición operativa	Fórmula/escala	Fuente de evidencia	Frecuencia	Criterio de aceptación
Eficiencia (tiempos de preparación)	Tprep	Tiempo total que tarda el asesor en preparar una sesión (definir contexto, restricciones y selección de juego)	Minutos; $\Delta\% = (T_{prep\_baseline} - T_{prep\_prototipo}) / T_{prep\_baseline} \times 100$ .	Cronometraje + logs de sistema + registro de tareas.	Por sesión de piloto	Meta a definir con CJEI; reporte de mediana y rango intercuartílico.
Eficiencia (tiempos de preparación)	Trec	Tiempo transcurrido desde que se envía la solicitud de recomendación hasta visualizar el Top-N y su explicación.	ms; p50/p95 en cada sesión.	Logs de backend / herramientas de medición (p. ej., herramientas de navegador)	Por caso de uso	Sin umbral fijado; se reporta distribución y se comparan endpoints críticos.
Consistencia de recomendaciones	Repetibilidad	Grado en que el sistema retorna el mismo conjunto y orden relativo ante el mismo perfil de sesión y configuración.	Jaccard@N y Kendall $\tau$ (opcional) sobre Top-N.	Ejecuciones repetidas con input controlado.	3 repeticiones por caso	Jaccard@10 cercano a 1.0 en condiciones idénticas.

Consistencia de recomendaciones	Tasa de “cero resultados”	Proporción de perfiles de sesión que no generan candidatos por restricciones incompatibles.	# sesiones sin resultados / # sesiones evaluadas.	Logs + reportes de prueba.	Por piloto	Se reporta y se analizan causas; se espera reducción al ajustar datos y reglas.
Preservación del conocimiento institucional	Cobertura de trazabilidad	Proporción de recomendaciones que almacenan snapshots inmutables de contexto, juego y configuración usada.	% recomendaciones con snapshot completo.	Registro de recomendación + endpoints de trazabilidad.	Continuo (automático)	100% en recomendaciones generadas (criterio funcional)
Preservación del conocimiento institucional	Uso de retroalimentación	Capacidad del sistema para registrar feedback post-sesión y explotarlo en analíticas y explicaciones.	Disponibilidad de campos + consistencia de agregados.	Pantallas UI + endpoints de feedback/analytics.	Por sesión / semanal	Registro completo y consultable ; sin errores de integridad.
Usabilidad	SUS	Puntuación de usabilidad percibida mediante System Usability Scale.	0–100 (SUS estándar)	Cuestionario SUS (10 ítems)	Cierre de piloto	Interpretación según umbrales SUS (reportar media/mediana)
Usabilidad	Éxito de tareas	Proporción de tareas completadas sin ayuda (p. ej., crear sesión, obtener recomendaciones, comparar, registrar feedback)	% éxito + errores críticos/no críticos.	Checklist de observación + grabación (si aplica)	Por tarea	≥ 80% éxito en tareas clave; análisis de errores.
Utilidad percibida	TAM-PU/PEOU	Utilidad percibida y facilidad de uso percibida	Escala Likert 1–5 (ítems definidos)	Cuestionario TAM + entrevista breve.	Cierre de piloto	Reporte de tendencia y verbatim;

		(constructos TAM)				sin umbral fijo.
Precisión / calidad técnica	Relevancia experta@N	Juicio experto sobre la pertinencia del Top-N para el contexto pedagógico, con base en criterios del CJEI.	Likert 1–5 por ítem + tasa de aceptación.	Rúbrica de evaluación experta + actas.	Por caso	Meta definida con CJEI; reporte de distribución y acuerdos.

Nota metodológica: algunos indicadores (p. ej., Jaccard@N, Kendall  $\tau$ ) se incluyen como opciones analíticas para capturar consistencia en ranking. Si el piloto se ejecuta con tamaño muestral reducido, se privilegiará análisis descriptivo y tendencias, complementado con evidencia cualitativa (observaciones, verbatim) para explicar hallazgos.

### Participantes y contexto de validación

La validación contempla dos niveles de participación: (i) validación técnica interna (desarrollador/investigador) para verificación funcional, consistencia y robustez; y (ii) validación con usuarios del rol objetivo (asesores pedagógicos del CJEI) orientada a usabilidad, utilidad y tiempos operativos. La participación se define con criterios de inclusión basados en rol, experiencia y familiaridad con el proceso de recomendación vigente. En todo caso, el tamaño muestral final dependerá de disponibilidad institucional y se registrará en el acta del piloto.

Tabla 8. Participantes

Rol	Perfil / criterios	Tipo de participación	Tareas principales	Evidencia aportada	Observaciones
Asesor pedagógico (CJ EI)	Usuario final; experiencia en diseño/acompañamiento de sesiones con juegos; conoce restricciones reales (tiempo, grupo, idioma)	Piloto de usabilidad y utilidad (interacción supervisada)	Crear perfil de sesión, solicitar recomendaciones, revisar explicaciones, comparar, seleccionar, registrar feedback.	SUS, TAM, tiempos, tasa de éxito, verbatim, observaciones.	Recomendable incluir variedad de experiencia; registrar años de experiencia y área.
Administrador del sistema (CJ EI)	Responsable de catálogo y taxonomía; gestiona	Validación de funciones de administrac	CRUD/ingesta, importación masiva, snapshots/versio nado de	Checklist funcional, incidencias, observacio	Puede ser el mismo asesor con rol ampliado,

	actualizaciones y auditoría.	ión (sesión técnica)	taxonomía, exportaciones y auditoría.	nes de calidad de datos.	según operación CJEL.
Investigador/desarrollador	Responsable del prototipo; ejecuta pruebas controladas y análisis.	Verificación técnica interna y soporte al piloto.	Ejecución de casos de prueba, revisión de logs, medición de rendimiento y robustez.	Resultados de pruebas técnicas, reporte de incidencias y mejoras.	Debe separar rol de facilitación y rol analítico para reducir sesgo.

### Diseño de pruebas piloto y casos de uso

El piloto se diseña alrededor de casos de uso que representan el flujo real del trabajo del CJEL: (1) disponer y actualizar el catálogo y su taxonomía; (2) describir el contexto de una sesión (objetivos, habilidades, restricciones operativas); (3) generar recomendaciones Top-N con filtros y scoring; (4) explicar y trazar por qué se recomienda un juego; (5) comparar alternativas; y (6) capturar retroalimentación post-sesión para aprendizaje institucional.

Los casos de uso se derivan de los módulos funcionales reportados en el repositorio: A) Ingesta y Normalización; B) Contexto de Clase; C) Taxonomía de Habilidades; D) Motor de Recomendación; E) Explicabilidad y Trazabilidad; F) Interfaz Web; G) Retroalimentación; H) Administración. A continuación, se define una matriz de casos de prueba (piloto) con trazabilidad a módulos y evidencia esperada:

Tabla 9. Matriz de casos

ID	Caso de uso	Objetivo	Precondiciones	Pasos resumidos	Resultado esperado	Módulos	Evidencia
CV-01	Crear perfil de sesión	Comprobar captura de objetivos, habilidades y restricciones.	Usuario autenticado; catálogo y taxonomía disponibles.	Ingresar objetivos; seleccionar habilidad primaria/secundaria; definir tiempo, tamaño de grupo e idioma; guardar.	Perfil persistente; validaciones y warnings cuando corresponda.	B, F	Checklist + logs + captura de pantalla (si aplica)
CV-02	Generar recomendaciones Top-N	Validar filtros duros	Existe perfil de	Solicitar recomendación; revisar	Listado con Top-N y	D, F	Resultados en pantalla

		y scoring híbrido.	sesión válido.	listado; ajustar Top-N; repetir.	metadatos; flag has_results cuando aplique.		+ endpoint + logs de scoring.
CV-03	Manejo de cero resultados	Validar detección y sugerencias de relajación.	Crear perfil con restricciones estrictas.	Solicitar recomendación; revisar análisis de causas y sugerencias; ajustar restricciones; reintentar.	Respuesta estructurada; sugerencias claras; reintento genera resultados si restricciones se relajan.	D, F	Captura de respuesta + registro de cambios.
CV-04	Explicación en lenguaje natural	Comprobar que cada recomendación incluye razones específicas.	Recomendaciones generadas.	Abrir detalle de recomendación; leer explicación; identificar razones y warnings.	≥3 razones por recomendación; desglose de componentes de scoring disponible.	E, F	Capturas + endpoint de explicación + checklist.
CV-05	Trazabilidad y reporte de auditoría	Verificar snapshots inmutables y consulta de trazabilidad.	Recomendación generada; historial de sesión.	Consultar trazabilidad por id; verificar que incluye perfil, juego y configuración.	Reporte completo; comparación operativa 2-5 recs (si aplica)	E, H	Salida endpoint /traceability + evidencia de consistencia.
CV-06	Comparar recomendaciones	Validar análisis lado a lado de alternativas.	Existe lista Top-N.	Seleccionar 2-5 recomendaciones; abrir comparación; revisar criterios.	Comparación operativa sin errores; criterios visibles.	E, F	Captura + registro de interacción.
CV-07	Registrar retroalimentación post-sesión	Validar captura de feedback y relación con sesión/recomendación.	Existe recomendación; usuario final.	Completar formulario de feedback (uso, score, comentarios); guardar; (opcional)	Registro persistido; estadísticas se actualizan; recomendación marcada	G, F	Registro DB + pantalla + endpoint POST/P UT.

				editar dentro de 7 días.	como seleccionada.		
CV-08	Consultar analíticas de feedback	Validar agregación y consulta de patrones.	Existe conjunto de feedback.	Abrir estadísticas por juego; abrir analíticas del sistema; filtrar por fecha.	Agregados coherentes ; top usados; joyas ocultas; candidatos a revisión.	G, H	Respuestas endpoint + revisión de coherencia.
CV-09	Importación masiva de catálogo	Validar importación CSV/JSON y control de calidad.	Archivo de importación disponible .	Ejecutar importación con estrategia update/skip/replace; validar rechazo si >20% inválidos.	Importación exitosa o rechazo controlado ; reporte de errores.	A, H	Log de importación + reporte de registros inválidos.
CV-10	Versionado de taxonomía (snapshot/activate)	Comprobar snapshots y activación de versión.	Taxonomía existente.	Crear snapshot; listar versiones; consultar versión; activar versión seleccionada.	Versiones persistentes; versión activa cambia; auditoría registrada.	H, C	Respuestas endpoints + auditoría .

### 1.1.3. Instrumentos y fuentes de evidencia

Los instrumentos se seleccionan para garantizar triangulación: evidencia observacional (interacción) evidencia objetiva (tiempos y logs) y evidencia subjetiva (cuestionarios y entrevistas) Para dimensionar el esfuerzo, los instrumentos se organizan en: (a) instrumentos de sesión (aplican por tarea); (b) instrumentos de cierre (aplican al final del piloto); y (c) instrumentos automáticos (generados por el sistema)

- Instrumento I1 – Lista de verificación por tarea (éxito, errores, ayudas solicitadas, desviaciones)
- Instrumento I2 – Registro de tiempos (Tprep, Trec, tiempos por tarea, tiempos de corrección)
- Instrumento I3 – Cuestionario SUS (10 ítems) para usabilidad global.
- Instrumento I4 – Cuestionario TAM (utilidad percibida y facilidad de uso percibida) adaptado al contexto CJEL.

- Instrumento I5 – Guion de entrevista semiestructurada (verbatim sobre valor, confianza y oportunidades de mejora)
- Instrumento I6 – Evidencia automática: logs del backend, endpoints de trazabilidad (/traceability/{id}) analíticas de feedback.
- Instrumento I7 – Rúbrica de evaluación experta de precisión/relevancia (definida con criterios CJEI)

Tabla 10 Matriz de instrumentos por dimensión:

Dimensión	I1 Checklist	I2 Tiempos	I3 SUS	I4 TAM	I5 Entrevista / logs
Eficiencia	✓	✓			logs (Trec)
Consistencia	✓ (cero resultados)				logs + repeticiones controladas
Preservación conocimiento	✓ (trazabilidad visible)				logs + endpoints /traceability + analíticas
Usabilidad	✓	✓ (tiempo por tarea)	✓		verbatim de fricciones
Utilidad percibida				✓	entrevista + ejemplos de valor
Precisión técnica	✓ (aceptación de recomendaciones)				rúbrica experta + trazabilidad

### Procedimiento de recolección (paso a paso)

El procedimiento se define para reducir variabilidad y sesgos de facilitación. Cada sesión de piloto debe ejecutarse con un guion de tareas, registrando tanto el desempeño como la percepción del participante. Se recomienda, cuando sea viable, realizar la sesión en el ambiente habitual de trabajo del asesor (o en un entorno controlado equivalente) con el mismo tipo de equipo y conectividad.

6. Preparación del ambiente: verificar prerequisites del sistema (backend Python 3.11+, PostgreSQL 14+, frontend Node 18+) base de datos inicializada con migraciones y datos semilla; confirmar acceso UI y API.
7. Alistamiento de materiales: imprimir o cargar formatos I1–I5; preparar cronómetro; habilitar recolección de logs (nivel INFO)
8. Briefing al participante: explicar propósito del piloto, alcance del prototipo, duración estimada y derechos del participante; obtener consentimiento informado (si aplica)
9. Aplicación de pre-test breve: capturar perfil del participante (rol, experiencia, frecuencia de uso de juegos, familiaridad con proceso actual)

10. Ejecución de tareas: aplicar los casos CV-01 a CV-08 (mínimo) siguiendo el orden del flujo; registrar tiempos y eventos críticos.
11. Debriefing: aplicar cuestionarios SUS y TAM; realizar entrevista semiestructurada (10–15 min) capturando verbatim.
12. Consolidación de evidencia: exportar logs relevantes, capturas y reportes de trazabilidad; almacenar en repositorio de evidencias con control de acceso.
13. Cierre: documentar incidencias, sugerencias y acciones correctivas priorizadas; acordar fecha de iteración o re-prueba si aplica.

### **Criterios de análisis y tratamiento de datos**

El tratamiento de datos combina análisis cuantitativo y cualitativo. En el componente cuantitativo se calcularán estadísticos descriptivos (media, mediana, desviación estándar y rango intercuartílico) para tiempos y escalas, junto con métricas de éxito por tarea y frecuencia de errores. Si se cuenta con mediciones antes/después para el mismo participante, se evaluará la diferencia con pruebas no paramétricas (p. ej., Wilcoxon) cuando el tamaño de muestra sea limitado y no se cumplan supuestos de normalidad.

En el componente cualitativo, los verbatim y observaciones se codificarán por temas relacionados con: confianza en la recomendación, claridad de explicaciones, fricciones de interfaz, adecuación del lenguaje/terminología al CJEI y valor percibido. La triangulación se aplicará contrastando (a) hallazgos reportados por participantes; (b) comportamientos observados durante tareas; y (c) trazas del sistema (logs y snapshots de trazabilidad)

Para la dimensión de consistencia, se realizarán repeticiones controladas de los mismos perfiles de sesión, con configuración de scoring fija. Se reportará la estabilidad del Top-N (por ejemplo, Jaccard@10) y se analizarán discrepancias explicando su origen (cambios en datos, filtros duros, o ajustes de pesos)

### **Consideraciones éticas, sesgos y limitaciones del piloto**

La validación se considera de riesgo mínimo, orientada a evaluación de un prototipo de software. Aun así, deben contemplarse: consentimiento informado cuando se recolecten datos personales (p. ej., nombre de asesor en feedback) minimización de datos, almacenamiento seguro de evidencias

y control de accesos. Se recomienda pseudonimizar participantes en reportes y separar evidencias identificables de los datos analíticos.

Sesgos potenciales incluyen: efecto Hawthorne (cambio de conducta por ser observado) sesgo de facilitación (el investigador guía en exceso) sesgo de deseabilidad social (evaluaciones más positivas por relación institucional) y sesgo de muestreo (participantes con mayor afinidad tecnológica) Para mitigarlos, se sugiere estandarizar el guion, registrar ayudas, y reportar limitaciones explícitamente.

## **7.2. Resultados de las pruebas**

En esta sección se reportan los resultados disponibles a partir de la verificación técnica interna y de los resultados de pruebas incluidos en la documentación del repositorio del prototipo. En particular, se reportan evidencias cuantificables sobre: (a) cobertura de implementación de requerimientos MUST (b) pruebas del motor de recomendación y manejo de escenarios realistas, y (c) pruebas del componente de explicabilidad y trazabilidad. Los resultados de usabilidad, utilidad percibida y reducción de tiempos de preparación requieren la ejecución del piloto con asesores y se documentan como pendientes, junto con el formato de reporte.

### **7.2.1 Caracterización del piloto**

El prototipo se ejecuta como sistema completo con un backend basado en FastAPI y un frontend web. La documentación del repositorio indica prerequisites de Backend (Python 3.11+ y PostgreSQL 14+) y Frontend (Node.js 18+) Para inicialización se contemplan migraciones de base de datos y un proceso de seeding de datos (juegos, habilidades y configuraciones) lo que permite evaluar el flujo de extremo a extremo con datos semilla.

En términos de estructura de información y cobertura funcional, se destacan componentes relevantes para la validación: una taxonomía jerárquica de habilidades de 4 niveles con 40 habilidades pre-cargadas; un vocabulario controlado con 50+ mecánicas estándar; y módulos de administración y auditoría orientados a preservar y gobernar el conocimiento institucional. Asimismo, el repositorio reporta tests de integración y unitarios (63+) lo cual soporta el componente de verificación técnica.

## **7.2.2 Resultados por dimensión (alineado a OE5 y pregunta 5)**

### ***7.2.2.1 Usabilidad (hallazgos, evidencia)***

Resultados disponibles: a la fecha se cuenta con evidencia indirecta derivada de la completitud del flujo UI (módulo F – Interfaz Web) y de la cobertura funcional end-to-end, pero no se dispone aún de métricas de usabilidad basadas en instrumentos con usuarios (SUS, éxito de tareas) porque el piloto con asesores no ha sido ejecutado. Por tanto, esta subsección establece el formato de reporte y los criterios de evidencia a recopilar, sin afirmar resultados no medidos.

Resultados pendientes (a recolectar en piloto): (i) puntuación SUS por participante y distribución; (ii) tasa de éxito por tarea en casos CV-01 a CV-08; (iii) errores críticos/no críticos y puntos de fricción; (iv) tiempo por tarea y necesidad de ayuda. El Instrumento I1 (checklist) y el Instrumento I3 (SUS) se anexan al final del capítulo.

### ***7.2.2.2 Utilidad percibida y aceptación por asesores (valoraciones, verbatim)***

Resultados disponibles: el repositorio evidencia la existencia de un módulo de retroalimentación (G) con campos obligatorios y opcionales, y la capacidad de producir estadísticas y analíticas del sistema. Sin embargo, la utilidad percibida y aceptación por asesores requiere interacción real y retroalimentación cualitativa. En consecuencia, se reporta como pendiente la aplicación del cuestionario TAM y la entrevista semiestructurada.

Resultados pendientes (a recolectar en piloto): (i) utilidad percibida (PU) y facilidad de uso percibida (PEOU) en escala Likert 1–5; (ii) confianza en la recomendación y en la explicación; (iii) verbatim sobre valor operativo (reducción de esfuerzo, claridad de criterios) y (iv) condiciones de adopción (integración con proceso actual del CJEI)

### ***7.2.2.3 Impacto en tiempos de preparación (resultados reportados)***

Resultados disponibles: el repositorio no reporta, a la fecha, mediciones de tiempos operativos “antes/después” con asesores. Por ello no se incluyen cifras de reducción de tiempo. Se documenta el mecanismo de medición y la estructura de datos para capturar evidencia objetiva durante el piloto. Complementariamente, se propone instrumentar logs de backend para obtener tiempos de respuesta de endpoints críticos y tiempos de procesamiento del motor de recomendación.

Resultados pendientes (a recolectar en piloto): Tprep\_baseline y Tprep\_prototipo por participante y por sesión; comparación por tipo de sesión (tamaño de grupo, restricciones fuertes, idioma); y análisis de tareas que concentran el tiempo (captura de contexto vs. exploración/comparación)

#### ***7.2.2.4 Consistencia de recomendaciones (resultados reportados)***

Resultados disponibles: el repositorio reporta resultados de pruebas del Módulo D (Motor de Recomendación) asociados a escenarios realistas. En particular, se documenta un “test pass rate” de 81,8% y que 4 de 13 sesiones realistas generan recomendaciones (30,8%) Además, se incluyen ejemplos exitosos de recomendaciones en perfiles específicos (p. ej., 4 jugadores/60 min → Ticket to Ride; 8 jugadores/30 min → Dixit; 2 jugadores/50 min → Ticket to Ride, Azul) Estos resultados constituyen evidencia preliminar del comportamiento del motor en diferentes restricciones.

Interpretación técnica: la tasa de sesiones sin recomendaciones no debe interpretarse como un defecto por sí misma, pues el sistema aplica filtros duros (disponibilidad, jugadores, tiempo  $\pm 20\%$ , idioma) y puede encontrar cero candidatos ante restricciones incompatibles con el catálogo. Desde la perspectiva de consistencia, el foco de validación es (a) que el sistema identifique correctamente el escenario de cero resultados; (b) que explique causas (grupo grande, tiempo, idioma) y sugiera relajaciones; y (c) que produzca recomendaciones reproducibles bajo entradas idénticas y configuración fija. Estas propiedades se verifican mediante los casos CV-02 y CV-03, y por repeticiones controladas (repetibilidad)

#### ***7.2.2.5 Preservación del conocimiento institucional (resultados reportados)***

Resultados disponibles: el repositorio reporta un componente de Explicabilidad y Trazabilidad (Módulo E) con dos capacidades centrales: (i) explicaciones en lenguaje natural con al menos tres razones específicas por recomendación, y (ii) trazabilidad completa e inmutable mediante snapshots del perfil de sesión, estado del juego y configuración de scoring. Asimismo, se reporta un 100% de aprobación en pruebas del módulo (5/5 tests) validando que RF-EXP-01 genera explicaciones con 4+ razones específicas y que RF-EXP-02 produce audit trails completos e inmutables, incluyendo comparación operativa y tracking histórico.

Adicionalmente, los módulos de retroalimentación y administración aportan preservación de conocimiento mediante: registro de feedback post-sesión, estadísticas agregadas por juego (promedio de utilidad, número de usos, distribución de calificaciones y comentarios recientes)

analíticas del sistema (top usados, “joyas ocultas”, “candidatos a revisión”) y auditoría de acciones administrativas con filtros por entidad/acción/usuario. En conjunto, estas capacidades habilitan un ciclo de aprendizaje institucional donde las recomendaciones dejan trazas interpretables y reutilizables.

#### ***7.2.2.6 Precisión, calidad técnica de la recomendación***

Resultados disponibles: la documentación del repositorio no reporta aún una evaluación de precisión basada en juicio experto o métricas offline (p. ej., Precision@K) con un conjunto de verdad-terreno definido por asesores. Por tanto, no se presentan métricas de precisión “final”. No obstante, el diseño del motor reportado es híbrido e incorpora cuatro componentes de scoring (habilidades, mecánicas, dificultad y ranking) lo que permite operacionalizar una evaluación de calidad técnica a partir de trazabilidad y rúbricas expertas.

Resultados pendientes (a recolectar en piloto): (i) evaluación experta de relevancia del Top-N por caso (rúbrica); (ii) tasa de aceptación del juego recomendado (selección) y del uso real (was\_used); (iii) validación de alineación entre habilidades objetivo declaradas y habilidades realmente trabajadas reportadas en feedback; y (iv) análisis de concordancia entre asesores.

#### **7.2.3 Síntesis de hallazgos y ajustes derivados**

La evidencia técnica disponible sugiere que el prototipo alcanza completitud funcional del MVP y que los componentes de trazabilidad y explicabilidad se encuentran implementados con pruebas aprobadas. Sin embargo, la evidencia del motor de recomendación en escenarios realistas indica que, bajo ciertas restricciones, una proporción relevante de perfiles no genera recomendaciones. Este hallazgo orienta ajustes en tres líneas: (a) fortalecimiento del catálogo y de la normalización de datos para incrementar cobertura; (b) afinamiento de reglas de negocio para relajar restricciones de forma guiada cuando el costo operativo lo permita; y (c) calibración de pesos del scoring mediante configuración y retroalimentación.

A nivel de validación, se prioriza ejecutar el piloto con asesores para completar las dimensiones de usabilidad, utilidad y eficiencia. Los resultados del piloto permitirán, además, ajustar el diseño de explicaciones para mejorar confianza y comprensión, y orientar el desarrollo de funcionalidades adicionales (por ejemplo, sugerencias más específicas ante cero resultados o recomendaciones alternativas por “cercanía” al perfil)

### 7.3. Evaluación de Rendimiento

La evaluación de rendimiento busca verificar que el prototipo responde de manera estable ante cargas razonables de uso institucional, y que las operaciones críticas (generación de recomendaciones, consulta de explicaciones y trazabilidad) mantienen tiempos de respuesta compatibles con un flujo de trabajo interactivo. Dado que el rendimiento depende del entorno (hardware, red, volumen de datos) se reportan métricas con su contexto de ejecución. Si no se dispone aún de mediciones instrumentadas, se presenta el protocolo y la matriz de medición para su ejecución.

#### 7.3.1 Rendimiento del sistema (tiempos de respuesta y carga)

Endpoints críticos sugeridos para pruebas de rendimiento:

- Generación de recomendaciones (servicio del Módulo D)
- Obtención de explicación y desglose de scoring (Módulo E)
- Consulta de trazabilidad (/traceability/{id}) y comparación de recomendaciones.
- Endpoints de administración (estadísticas y dashboard) por su agregación de datos.

Protocolo recomendado de prueba de carga:

- 1) Definir un conjunto de perfiles de sesión representativos (variando tamaño de grupo, tiempo, idioma y habilidades)
- 2) Ejecutar ráfagas controladas de solicitudes concurrentes (p. ej., 1, 5, 10, 20 usuarios virtuales) durante ventanas fijas.
- 3) Medir tiempos p50/p95/p99, tasa de errores HTTP, y throughput.
- 4) Identificar cuellos de botella (DB, CPU en scoring, serialización de respuestas) mediante logs y monitoreo.
- 5) Repetir bajo diferentes tamaños de Top-N (1–50) para analizar sensibilidad.

Criterios de reporte: para cada nivel de carga se reporta una tabla con tiempos de respuesta por endpoint (p50/p95) errores y utilización de recursos cuando esté disponible. En caso de no instrumentar recursos, al menos se reporta p95 y tasa de error.

### 7.3.2 Rendimiento del procesamiento de datos y recomendación

El procesamiento del motor de recomendación incorpora filtros duros y un scoring híbrido con cuatro componentes. En pruebas de rendimiento, se recomienda medir el tiempo desagregado de: (a) filtrado de candidatos; (b) cálculo de similitud y scoring; (c) construcción de explicaciones; y (d) persistencia de trazas (recomendación y snapshots) Esta desagregación permite distinguir si el costo principal proviene de DB (consultas) o de CPU (cálculo de scoring/explicación)

Matriz de pruebas sugerida: variar el tamaño del catálogo (por ejemplo, datos semilla vs. catálogo ampliado) y el Top-N, registrando impacto en tiempo de procesamiento. Si el prototipo se despliega con Docker, se recomienda repetir pruebas tanto en modo desarrollo como en modo containerizado para observar diferencias de latencia y performance.

### 7.3.3 Robustez y manejo de casos límite

La robustez se evalúa verificando que el prototipo responde de manera controlada ante entradas atípicas o inconsistentes, sin comprometer la integridad del sistema ni producir fallos no manejados. El repositorio reporta reglas y validaciones relevantes, como: rechazo de importación si >20% de registros inválidos; validación de suma de pesos del scoring igual a 1,0 ( $\pm 0,001$ ); y warnings no bloqueantes ante restricciones como grupos grandes o tiempos muy limitados.

Tabla 11 Matriz de casos límite propuesta:

ID	Caso límite	Entrada/condición	Componente	Respuesta esperada	Evidencia
RB-01	Importación con alta invalidez	>20% registros inválidos en CSV/JSON	Módulo A (ingesta)	Rechazo controlado + reporte de errores	Log + conteo inválidos
RB-02	Pesos de scoring inválidos	Suma de pesos $\neq 1.0$ ( $\pm 0.001$ )	Módulo D (config)	Error de validación; no se activa config	Respuesta API + DB
RB-03	Cero candidatos por restricciones	Idioma/tiempo/jugadores incompatibles	Módulo D	has_results=False; causas y sugerencias	Respuesta API + UI
RB-04	Grupo muy grande	Grupo >30	Módulo B (validación)	Warning no bloqueante; sugerencias (dividir grupo)	UI + log warning
RB-05	Complejidad alta en poco tiempo	Complejidad >4 con tiempo <30	E + B	Warning + explicación contextual	Explicación + UI
RB-06	Eliminación de habilidad	Habilidad con juegos asignados e hijos	H (impacto)	can_delete=False; lista afectada	Endpoint impacto + auditoría

	con dependencias				
RB-07	Feedback editable fuera de ventana	Editar después de 7 días	G (feedback)	Rechazo o bloqueo controlado	Respuesta API + UI

## 8. Discusión

Este capítulo discute los hallazgos del desarrollo del prototipo del sistema de recomendación de juegos de mesa para el aprendizaje basado en juegos, contrastando las decisiones de diseño, la arquitectura implementada y el plan de validación con la literatura especializada en sistemas de recomendación, procesamiento de lenguaje natural y aprendizaje basado en juegos. La discusión se organiza en torno a: (i) la pertinencia técnica de un recomendador híbrido y controlable en un contexto institucional; (ii) el aporte del prototipo en explicabilidad, trazabilidad y preservación de conocimiento; y (iii) la coherencia pedagógica al representar objetivos y habilidades y al vincularlos con la selección de juegos de mesa.

### 8.1. Selección del enfoque de recomendación: pertinencia del híbrido frente a alternativas

La literatura de referencia diferencia enfoques basados en contenido, filtrado colaborativo, modelos de factorización y estrategias híbridas, y plantea que la elección depende del tipo de señal disponible, del volumen de datos y de las restricciones del dominio [1], [2], [10]. En entornos organizacionales donde el histórico de interacciones es escaso o se encuentra en construcción — condición frecuente en instituciones que recomiendan recursos pedagógicos con apoyo de criterios expertos—, los enfoques puramente colaborativos y de factorización tienden a enfrentar el problema de arranque en frío, pues requieren densidad y continuidad de feedback usuario–ítem para estabilizar sus estimaciones [8], [9]. En consecuencia, priorizar un enfoque basado en contenido, complementado con reglas operativas y ponderaciones configurables, se alinea con la recomendación híbrida como combinación de señales y conocimiento del dominio para mitigar limitaciones de datos [5].

Esta decisión también es coherente con la evolución conceptual del campo: Adomavicius y Tuzhilin sostienen que un recomendador de nueva generación debe balancear personalización con restricciones prácticas y con la calidad de la interacción usuario–sistema [3]. En el contexto del CJEI, la recomendación debe ser comprensible y justificable para el rol asesor, lo que favorece diseños donde el razonamiento pueda explicarse a partir de atributos y reglas visibles, y donde el sistema permita calibración de pesos y criterios sin depender de entrenamiento costoso o de grandes volúmenes de datos [1], [2].

De forma contrastiva, las alternativas clásicas presentan ventajas y riesgos específicos en este dominio. Los enfoques basados en contenido aprovechan metadatos del juego (mecánicas, complejidad, duración, idioma, habilidades objetivo) y resultan apropiados para arranque en frío; sin embargo, su desempeño depende de la calidad y completitud del catálogo, y pueden sesgarse hacia ítems con descripción más rica [10]. El filtrado colaborativo puede descubrir relaciones emergentes, pero requiere histórico suficiente y es sensible a sesgos de popularidad y a la variabilidad de usuarios [4], [8]. Modelos de factorización y factorización de máquinas son eficientes y robustos cuando hay señal; no obstante, su adopción en un contexto institucional educativo puede demandar capas adicionales de interpretabilidad para sostener confianza y auditoría [2], [12].

Finalmente, los sistemas de recomendación basados en deep learning han mostrado avances al integrar representaciones ricas y señales heterogéneas; sin embargo, su efectividad suele estar asociada a escala de datos, capacidad de experimentación y gobernanza, condiciones que no siempre están presentes en un MVP institucional [17]. Por ello, la estrategia de evolución más coherente con la bibliografía consiste en iniciar con un híbrido controlable y, a medida que se consolide el histórico de retroalimentación, incorporar aprendizaje incremental, comparando variantes mediante métricas offline y evaluaciones con usuarios [1], [8].

## **8.2. Reglas de negocio, filtros duros y coherencia con el enfoque usuario-centrista**

Resnick y Varian caracterizan los recomendadores como sistemas socio-técnicos que median entre preferencias, restricciones y objetivos; por ello, las reglas de negocio y el diseño de interacción condicionan el valor percibido [4]. En el CJEI, restricciones operativas como disponibilidad del juego, rango de jugadores, tiempo y dependencia de idioma no son negociables en la práctica cotidiana. En consecuencia, la decisión de aplicar filtros duros antes del ranking se alinea con la práctica de asegurar factibilidad y luego optimizar relevancia dentro del conjunto viable, lo cual aumenta la utilidad práctica del sistema y reduce recomendaciones inviables [1], [2].

Además, el manejo explícito del caso “cero resultados” es crítico para la confianza. En recomendación, la experiencia negativa de recibir una lista vacía sin explicación deteriora la percepción de competencia del sistema. Por ello, la estrategia de reportar causas (qué restricción bloquea) y sugerir relajaciones razonables se alinea con principios de diseño centrado en el usuario y con enfoques híbridos que integran conocimiento del dominio para guiar la interacción [1], [5].

### **8.3. Explicabilidad, trazabilidad y preservación de conocimiento: aporte diferencial del prototipo**

La literatura contemporánea destaca que la aceptación de un recomendador depende de transparencia, confianza, control y capacidad de auditoría, en especial cuando se utiliza para apoyar decisiones con impacto real en procesos organizacionales [1]. En el dominio pedagógico, esta exigencia se intensifica: los asesores requieren justificar por qué un juego se considera adecuado para ciertos objetivos y para un grupo específico. En ese sentido, el prototipo prioriza explicaciones interpretables y trazabilidad de decisión como mecanismos para preservar conocimiento institucional.

Burke muestra que los recomendadores híbridos permiten balancear precisión y explicabilidad al combinar componentes con distinta naturaleza [5]. El prototipo se aproxima a esa recomendación al construir explicaciones a partir de factores de scoring interpretables (habilidades objetivo, mecánicas, dificultad y ranking) y al almacenar rastros (snapshots) de contexto y configuración. Este diseño reduce el carácter de “caja negra” propio de enfoques puramente latentes si no se complementan con mecanismos explicativos, y habilita auditoría y mejora iterativa basada en evidencia de retroalimentación [1], [2].

### **8.4. Taxonomía pedagógica y selección de juegos: alineación con teorías del aprendizaje**

La representación explícita de objetivos y habilidades responde a la necesidad de traducir un recurso lúdico a criterios pedagógicos verificables. Bloom propone una clasificación de objetivos cognitivos que ha sido ampliamente utilizada para diseñar objetivos instruccionales y mapear actividades a niveles de complejidad [39]. Al incorporar una taxonomía de habilidades, el prototipo establece un lenguaje común entre el catálogo (juegos) y el diseño de la sesión, reduciendo ambigüedad y apoyando trazabilidad.

Complementariamente, Gagné plantea condiciones del aprendizaje y eventos instruccionales que enfatizan guía, práctica y retroalimentación [40]. En el uso de juegos de mesa con fines educativos, el valor depende de la preparación de la actividad, el acompañamiento y el debriefing. Por ello, un sistema de recomendación no sustituye el diseño pedagógico; su contribución radica en facilitar selección informada y coherente con los objetivos, y en alertar sobre condiciones operativas relevantes (por ejemplo, complejidad alta o requisitos de mesa/espacio)

Desde teorías sociocognitivas y experienciales, Bandura resalta el aprendizaje por observación y la dimensión social del contexto [41], mientras que Kolb conceptualiza el aprendizaje como un ciclo de experiencia y reflexión [42]. Estos marcos son compatibles con el aprendizaje basado en juegos, donde la experiencia se convierte en aprendizaje mediante reflexión guiada y transferencia. Para sostener coherencia, Biggs y Tang proponen la alineación constructiva entre objetivos, actividades y evaluación [43]; así, la recomendación aporta valor cuando está anclada a objetivos/habilidades y no solo a preferencias lúdicas.

### **8.5. Aprendizaje basado en juegos, gamificación y juegos de mesa: evidencia, heterogeneidad y cautelas**

La bibliografía sobre gamificación y aprendizaje basado en juegos reporta efectos positivos en motivación y compromiso, pero con alta variabilidad según diseño instruccional, contexto y características del estudiantado [31], [33]. Hamari et al. subrayan que el efecto depende de cómo se implementan elementos de juego y de su coherencia con objetivos educativos [31], mientras que Plass et al. plantean fundamentos donde mecánicas, feedback y objetivos cognitivos deben alinearse [29]. En consecuencia, la recomendación de juegos de mesa debe considerar más que la “diversión”: debe sostener una correspondencia razonable entre mecánicas y habilidades objetivo.

En cuanto a juegos de mesa, revisiones sistemáticas reportan beneficios potenciales en dimensiones cognitivas y socioemocionales, aunque advierten limitaciones metodológicas y heterogeneidad en las medidas y poblaciones [32]. Wouters et al. señalan que los juegos serios pueden favorecer aprendizaje y motivación, pero el efecto se modula por soporte instruccional y contexto [33]. Esta evidencia respalda la necesidad del plan de validación propuesto: la utilidad del prototipo debe demostrarse mediante piloto con asesores (usabilidad, tiempos y precisión percibida) y no asumirse por analogía con resultados generales de la literatura.

Finalmente, trabajos que proponen criterios pedagógicos para seleccionar juegos de mesa enfatizan la importancia de objetivos, dinámica de grupo y transferencia de habilidades como criterios explícitos [45]. Esta línea converge con el diseño del prototipo, que exige declarar objetivos/habilidades y restricciones y busca sistematizar el conocimiento de los asesores mediante retroalimentación estructurada.

## **8.6. Procesamiento semántico (NLP) como capacidad incremental: pertinencia y prudencia**

El uso de NLP para enriquecer información del catálogo o asistir la asignación de habilidades se vincula con técnicas de representación semántica. Mikolov et al. proponen embeddings eficientes basados en predicción [14], Pennington et al. presentan GloVe basado en co-ocurrencias globales [15], y Devlin et al. introducen BERT como modelo transformador bidireccional para tareas de lenguaje [16]. Jurafsky y Martin sistematizan técnicas, evaluación y riesgos de sesgo en NLP [18]. Estas referencias sustentan que es técnicamente viable incorporar asistencia semántica para mapear textos de descripción a habilidades o mecánicas, pero también que dicha incorporación requiere evaluación y gobernanza.

Desde la perspectiva de ingeniería, un MVP institucional con catálogo acotado puede obtener mayor retorno primero consolidando metadatos y taxonomía y luego incorporar NLP en un esquema human-in-the-loop, donde el asesor confirma o corrige sugerencias, preservando control y trazabilidad. Esta prudencia es consistente con la literatura de recomendación basada en deep learning, que reconoce el costo de datos y experimentación y sugiere que el beneficio es mayor cuando existe escala y señal diversa [17].

## **8.7. Evaluación del prototipo: discusión metodológica sobre métricas offline y evaluación con usuarios**

Las evaluaciones pueden ser offline (métricas sobre datasets) online (experimentos) o centradas en usuario (estudios de usabilidad y utilidad) Harper y Konstan describen cómo datasets como MovieLens habilitan evaluación offline y comparabilidad, pero advierten que la evaluación debe reflejar contexto real de uso [8]. En el prototipo, el plan de validación prioriza dimensiones socio-técnicas —eficiencia, consistencia, preservación del conocimiento, usabilidad, utilidad percibida y precisión por juicio experto— porque el éxito institucional depende de adopción y confianza, no solo de una métrica de ranking [1].

Esta elección se refuerza al contrastar con sistemas industriales: el sistema de recomendación de YouTube integra múltiples señales, reglas y optimización continua con objetivos múltiples, evidenciando que la ingeniería real de recomendación excede el algoritmo y requiere instrumentación y experimentación [11]. En el ámbito educativo, el “éxito” también incluye

alineación pedagógica, por lo que instrumentos como SUS/TAM y verbatim aportan evidencia sobre fricciones, confianza y valor, complementando la medición de precisión.

### **8.8. Limitaciones del enfoque y amenazas a la validez**

Las limitaciones esperables del enfoque incluyen dependencia de la calidad de metadatos (sesgo hacia juegos mejor descritos) y potencial de sobre-especialización típica del contenido [10]. Asimismo, el uso de rankings externos como señal secundaria puede introducir sesgos de popularidad que no necesariamente se alinean con objetivos pedagógicos, por lo que su rol debe mantenerse auditable y calibrable [1], [2]. Finalmente, la preservación de conocimiento depende de disciplina de registro: si el feedback no se captura de forma sistemática, el sistema no podrá aprender ni producir analíticas institucionales de alto valor.

Metodológicamente, el piloto puede estar limitado por tamaño muestral y por variabilidad de contextos, por lo que la validez interna se fortalece mediante guiones estandarizados, registro de ayudas y captura de condiciones de ejecución. La validez externa dependerá de la representatividad de los asesores y de la diversidad de sesiones. En todo caso, la interpretación de resultados debe reconocer que la recomendación es un habilitador de selección y justificación, pero no una garantía directa de aprendizaje sin un diseño instruccional adecuado.

## 9. CONCLUSIONES

El prototipo desarrollado consolida un proceso institucional de recomendación de juegos de mesa al integrar catálogo, taxonomía pedagógica, motor de recomendación, interfaz y mecanismos de trazabilidad, fortaleciendo la preservación y transferencia del conocimiento del CJEI y habilitando una mejora continua basada en evidencia.

Se logró estructurar y normalizar la información relevante del dominio de juegos de mesa para el CJEI, definiendo atributos operativos y escalas que permiten recomendaciones basadas en datos consistentes y comparables.

Se diseñó y documentó una taxonomía pedagógica de habilidades y objetivos de aprendizaje que actúa como puente entre el lenguaje del juego y el lenguaje de la planificación educativa, incrementando coherencia y trazabilidad de la selección.

Se especificaron requerimientos funcionales y no funcionales alineados con el contexto real de los asesores del CJEI, delimitando un MVP verificable y criterios de aceptación orientados a desarrollo y validación.

Se implementó un prototipo end-to-end con arquitectura modular que integra reglas operativas, filtrado basado en contenido y un scoring híbrido configurable, permitiendo generar recomendaciones y presentarlas mediante una interfaz orientada a tareas del asesor.

Se definió un plan de validación replicable que operacionaliza la evaluación del prototipo mediante métricas de eficiencia, consistencia, preservación de conocimiento, usabilidad, utilidad percibida y precisión, dejando establecido el procedimiento y los instrumentos necesarios para recolectar evidencia empírica con asesores.

## 10. Trabajo futuro

Las conclusiones permiten proponer líneas de trabajo futuro orientadas a robustecer el sistema, ampliar cobertura del dominio, fortalecer el aprendizaje institucional y mejorar la experiencia del usuario final. Las acciones priorizadas se describen a continuación.

- Ampliación y curaduría del catálogo: incrementar cobertura de juegos disponibles y mejorar completitud de atributos, priorizando aquellos que impactan el filtrado duro y el scoring.
- Mejora del manejo de “cero resultados”: incorporar sugerencias más específicas y estrategias de relajación guiada, incluyendo alternativas por habilidades secundarias y modalidades de uso por estaciones.
- Aprendizaje a partir de feedback: activar y calibrar el reordenamiento por retroalimentación histórica, definiendo umbrales y condiciones de contexto similar, con auditoría del impacto.
- Personalización por asesor: implementar favoritos y exclusiones para capturar preferencias y restricciones idiosincráticas, manteniendo coexistencia con reglas generales del CJEI.
- Capacidad semántica incremental (NLP): añadir asistencia de sugerencia de habilidades a partir de descripciones y mecánicas, bajo enfoque human-in-the-loop y con conjuntos de validación.
- Evaluación offline: construir un dataset institucional curado (sesión–recomendación–feedback) para métricas offline (Precision@K, NDCG@K) y comparación de variantes del motor.
- Analíticas y gobierno del conocimiento: fortalecer dashboards institucionales, exportaciones y reglas de auditoría para soportar decisiones operativas y curaduría.
- Despliegue y operación: definir estrategia reproducible (p. ej., contenedores) monitoreo y pruebas de carga para soportar concurrencia y estabilidad.
- Investigación pedagógica complementaria: evaluar, en estudios posteriores, relación entre juegos recomendados y resultados de aprendizaje considerando diseño instruccional y debriefing.

## 11. Bibliografía

- [1] F. Ricci, L. Rokach, y B. Shapira eds; *Recommender Systems Handbook*, 3rd ed. Cham, Switzerland: Springer, 2022. doi: 10.1007, 978, 1, 0716, 2197, 4.
- [2] C. C. Aggarwal, *Recommender Systems: The Textbook*. Cham, Switzerland: Springer, 2016. doi: 10.1007, 978, 3, 319, 29659, 3.
- [3] G. Adomavicius y A. Tuzhilin, “Toward the next generation of recommender systems: A survey of the state, of, the, art and possible extensions,” *IEEE Trans. Knowl. Data Eng.*; vol. 17, no. 6, pp. 734–749, 2005. doi: 10.1109, TKDE.2005.99.
- [4] P. Resnick y H. R. Varian, “Recommender systems,” *Commun. ACM*, vol. 40, no. 3, pp. 56–58, Mar. 1997. doi: 10.1145, 245108.245121.
- [5] R. Burke, “Hybrid recommender systems: Survey and experiments,” *User Modeling and User, Adapted Interaction*, vol. 12, no. 4, pp. 331–370, 2002. doi: 10.1023, A:1021240730564.
- [6] X. Amatriain y J. M. Pujol, “Data mining methods for recommender systems,” in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, y P. B. Kantor eds. Boston, MA: Springer, 2011, pp. 39–71. doi: 10.1007, 978, 0, 387, 85820, 3\_2.
- [7] J. Bobadilla, F. Ortega, A. Hernando, y A. Gutiérrez, “Recommender systems survey,” *Knowledge, Based Systems*, vol. 46, pp. 109–132, 2013. doi: 10.1016, j.knosys.2013.03.012.
- [8] F. Maxwell Harper y J. A. Konstan, “The MovieLens datasets: History and context,” *ACM Trans. Interact. Intell. Syst.*; vol. 5, no. 4, pp. 1–19, 2015. doi: 10.1145, 2827872.
- [9] Y. Koren, R. Bell, y C. Volinsky, “Matrix factorization techniques for recommender systems,” *Computer*, vol. 42, no. 8, pp. 30–37, 2009. doi: 10.1109, MC.2009.263.
- [10] P. Lops, M. de Gemmis, y G. Semeraro, “Content, based recommender systems: State of the art and trends,” in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, y P. B. Kantor eds. Boston, MA: Springer, 2011, pp. 73–105. doi: 10.1007, 978, 0, 387, 85820, 3\_3.
- [11] J. Davidson et al; “The YouTube video recommendation system,” in *Proc. 4th ACM Conf. Recommender Systems (RecSys ’10)* Barcelona, Spain: ACM, 2010, pp. 293–296. doi: 10.1145, 1864708.1864770.

- [12] S. Rendle, “Factorization machines,” in 2010 IEEE Int. Conf. Data Mining. Sydney, Australia: IEEE, 2010, pp. 995–1000. doi: 10.1109, ICDM.2010.127.
- [13] K. He, X. Zhang, S. Ren, y J. Sun, “Deep residual learning for image recognition,” in Proc. IEEE Conf. Comput. Vis. Pattern Recognit (CVPR) Las Vegas, NV, USA: IEEE, 2016, pp. 770–778. doi: 10.1109, CVPR.2016.90.
- [14] T. Mikolov, K. Chen, G. Corrado, y J. Dean, “Efficient estimation of word representations in vector space,” arXiv:1301.3781, 2013.
- [15] J. Pennington, R. Socher, y C. D. Manning, “GloVe: Global vectors for word representation,” in Proc. 2014 Conf. Empirical Methods in Natural Language Processing (EMNLP) Doha, Qatar: ACL, 2014, pp. 1532–1543. doi: 10.3115, v1, D14, 1162.
- [16] J. Devlin, M., W. Chang, K. Lee, y K. Toutanova, “BERT: Pre, training of deep bidirectional transformers for language understanding,” in Proc. NAACL, HLT 2019. Minneapolis, MN, USA: ACL, 2019, pp. 4171–4186. doi: 10.18653, v1, N19, 1423.
- [17] L. Huang, H. Zhou, y H. Liu, “A survey of deep learning, based recommender systems,” *Front. Comput. Sci*; vol. 15, no. 3, 2021. doi: 10.1007, s11704, 020, 9268, 7.
- [18] D. Jurafsky y J. H. Martin, *Speech and Language Processing*, 3rd ed; online manuscript, 2025. Disponible en: <https://web.stanford.edu/~jurafsky, slp3>. (consulta: 10, ago, 2025)
- [19] C. Velázquez, Callado, “Impacto de los juegos de mesa en el aprendizaje escolar: revisión sistemática de la literatura,” *Revista Educación*, vol. 49, no. 1, 2025, doi: 10.15517, revedu.v49i1.60948. Archivo de Revistas UCR
- [20] F. J. Aguirregabiria Barturen y M. I. Ariceta Iraola, “ELEGAR, un juego de mesa para disfrutar y aprender las operaciones matemáticas básicas: Percepciones de alumnado de Educación Primaria,” *Revista de Investigación en Didáctica de las Matemáticas*, no. 18, pp. 1–20, 2021.
- [21] S. S. P. S. Liyanagunawardena y A. A. Williams, “Gamification for learning: A systematic review of the literature,” *J. Educ. Technol. Syst*; vol. 45, no. 1, pp. 1–24, 2016.
- [22] K. M. Kapp, *The Gamification of Learning and Instruction*. San Francisco, CA: Pfeiffer, 2012.
- [23] S. Deterding, D. Dixon, R. Khaled, y L. Nacke, “From game design elements to gamefulness: defining ‘gamification’,” in Proc. 15th Int. Academic MindTrek Conf

- (MindTrek '11) Tampere, Finland: ACM, 2011, pp. 9–15. doi: 10.1145, 2181037.2181040.
- [24] J. Huizinga, *Homo Ludens*. Madrid: Alianza Editorial, 2000.
- [25] R. Caillois, *Los juegos y los hombres: La máscara y el vértigo*. México: Fondo de Cultura Económica, 1994.
- [26] J. P. Gee, *What Video Games Have to Teach Us About Learning and Literacy*, 2nd ed. New York, NY: Palgrave Macmillan, 2007.
- [27] J. P. Gee, “Learning by design: Good video games as learning machines,” *E, Learning*, vol. 2, no. 1, pp. 5–16, 2005. doi: 10.2304, elea.2005.2.1.5.
- [28] B. V. O’Donnell, “Game, based learning in higher education: A meta, analysis,” *Educ. Technol. Res. Dev*; vol. 68, pp. 2195–2222, 2020. doi: 10.1007, s11423, 020, 09788, 2.
- [29] J. A. Plass, B. D. Homer, y C. K. Kinzer, “Foundations of game, based learning,” *Educ. Psychol*; vol. 50, no. 4, pp. 258–283, 2015. doi: 10.1080, 00461520.2015.1122533.
- [30] A. K. Pellas y P. Kazanidis, “The impact of game, based learning on students’ engagement and learning outcomes in higher education: A systematic review,” *Computers y Education*, vol. 203, 2023. doi: 10.1016, j.compedu.2023.104728.
- [31] J. Hamari, J. Koivisto, y H. Sarsa, “Does gamification work? A literature review of empirical studies on gamification,” in *Proc. 47th Hawaii Int. Conf. System Sciences (HICSS)* Waikoloa, HI, USA: IEEE, 2014, pp. 3025–3034. doi: 10.1109, HICSS.2014.377.
- [32] S. Noda, K. Shirotaki, y M. Nakao, “The effectiveness of intervention with board games: A systematic review,” *Biopsychosoc Med*; vol. 13, no. 1, 2019. doi: 10.1186, s13030, 019, 0146, 1.
- [33] L. M. N. Wouters, C. van Nimwegen, H. van Oostendorp, y E. D. van der Spek, “A meta, analysis of the cognitive and motivational effects of serious games,” *J. Educ. Psychol*; vol. 105, no. 2, pp. 249–265, 2013. doi: 10.1037, a0031311.
- [34] D. R. Michael y S. L. Chen, *Serious Games: Games That Educate, Train, and Inform*. Boston, MA: Thomson Course Technology, 2006.
- [35] N. R. Council, *Learning Science Through Computer Games and Simulations*. Washington, DC: The National Academies Press, 2011. doi: 10.17226, 13078.

- [36] J. M. Moreno, “Diseño de actividades basadas en juegos para educación superior: guía práctica,” *Revista Iberoamericana de Tecnología en Educación y Educación en Tecnología*, no. 29, pp. 30–40, 2021.
- [37] S. Romero, L. Usart, y M. Ott, “Can serious games contribute to developing and sustaining 21st century skills? A systematic review,” *Computers y Education*, vol. 144, 2020. doi: 10.1016/j.compedu.2019.103713.
- [38] A. I. Barab, M. Gresalfi, y A. Ingram, Goble, “Transformational play: Using games to position person, content, and context,” *Educ. Res;* vol. 39, no. 7, pp. 525–536, 2010. doi: 10.3102, 0013189X10386593.
- [39] B. S. Bloom, *Taxonomy of Educational Objectives: The Classification of Educational Goals*. New York, NY: Longmans, Green, 1956.
- [40] R. M. Gagné, *The Conditions of Learning*, 4th ed. New York, NY: Holt, Rinehart and Winston, 1985.
- [41] A. Bandura, *Social Learning Theory*. Englewood Cliffs, NJ: Prentice Hall, 1977.
- [42] D. A. Kolb *experiential Learning: Experience as the Source of Learning and Development*. Englewood Cliffs, NJ: Prentice Hall, 1984.
- [43] J. Biggs y C. Tang, *Teaching for Quality Learning at University*, 4th ed. Maidenhead, UK: Open University Press, 2011.
- [44] K. A. Ericsson, R. T. Krampe, y C. Tesch, Römer, “The role of deliberate practice in the acquisition of expert performance,” *Psychol. Rev;* vol. 100, no. 3, pp. 363–406, 1993. doi: 10.1037, 0033, 295X.100.3.363.
- [45] P. Chacón, "Criterios pedagógicos para la selección de juegos de mesa: una propuesta para la enseñanza de objetivos," *Didáct. Leng. Lit;* vol. 26, no. 1, pp. 112–128, 2024.
- [46] H. Gardner, *Frames of Mind: The Theory of Multiple Intelligences*. New York, NY: Basic Books, 1983.
- [47] Partnership for 21st Century Skills (P21), *Framework for 21st Century Learning*. Battelle for Kids, 2019. Disponible en: <http://www.battelleforkids.org/networks/p21> (consulta: 26, dic, 2025)

## 12. Anexos

### Anexo A. Diagramas de Arquitectura (Modelo C4)

El modelo C4 (Context, Container, Component, Code) permite visualizar la arquitectura del sistema en diferentes niveles de abstracción. Los siguientes diagramas muestran la estructura del Sistema de Recomendación CJEI desde una perspectiva de alto nivel hasta los componentes internos.

#### A.1. Diagrama de contexto

El diagrama de contexto muestra el sistema en su entorno, identificando los actores principales (Asesor Pedagógico y Administrador) y sus interacciones con el Sistema CJEI y sistemas externos como BoardGameGeek.

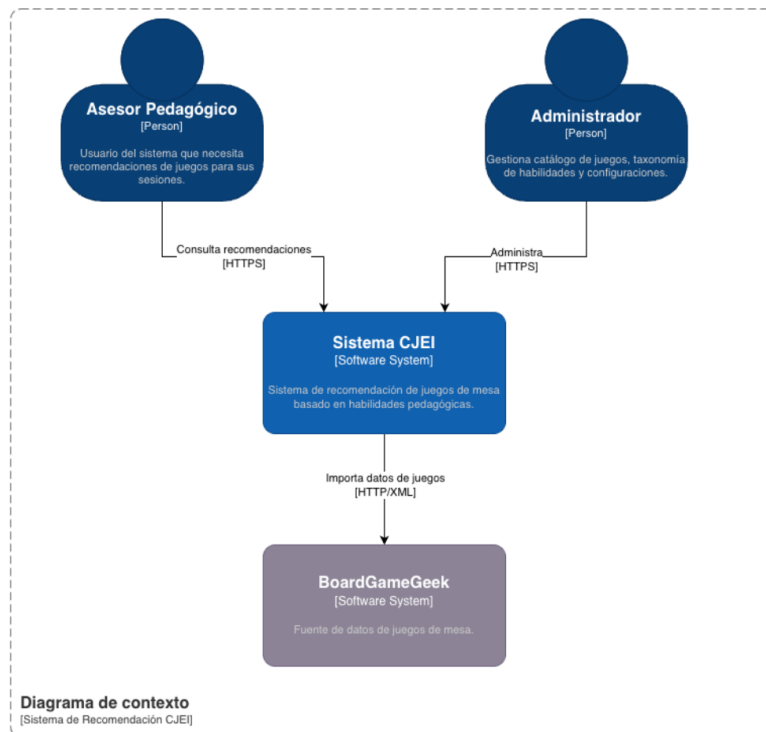


Figura A.1: Diagrama de Contexto - Nivel 1 del modelo C4

## A.2. Diagrama de Contenedores

El diagrama de contenedores descompone el sistema en sus principales bloques ejecutables: la Aplicación Web (React), la API (FastAPI), y la Base de Datos (PostgreSQL). Cada contenedor tiene responsabilidades claras y se comunica mediante protocolos definidos.

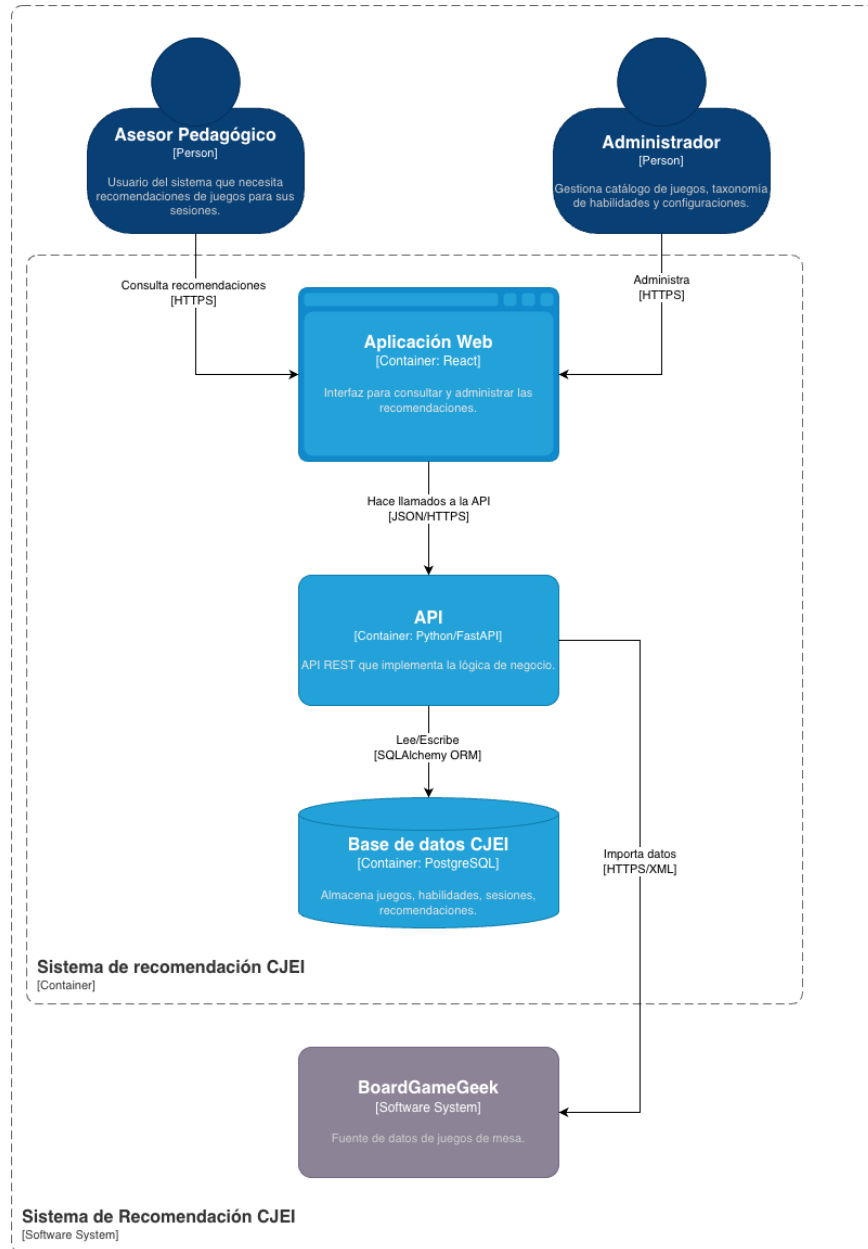


Figura A.2: Diagrama de Contenedores - Nivel 2 del modelo C4

### A.3. Diagrama de Componentes

El diagrama de componentes detalla la estructura interna de la API, mostrando los servicios especializados que implementan la lógica de negocio: Sessions Service, Recommendations Service, Games Service, Skills Service, Feedback Service, Admin Service, Recommendation Engine y Skill Analyzer. Cada componente tiene responsabilidades bien delimitadas y se comunica con la base de datos mediante SQLAlchemy ORM.

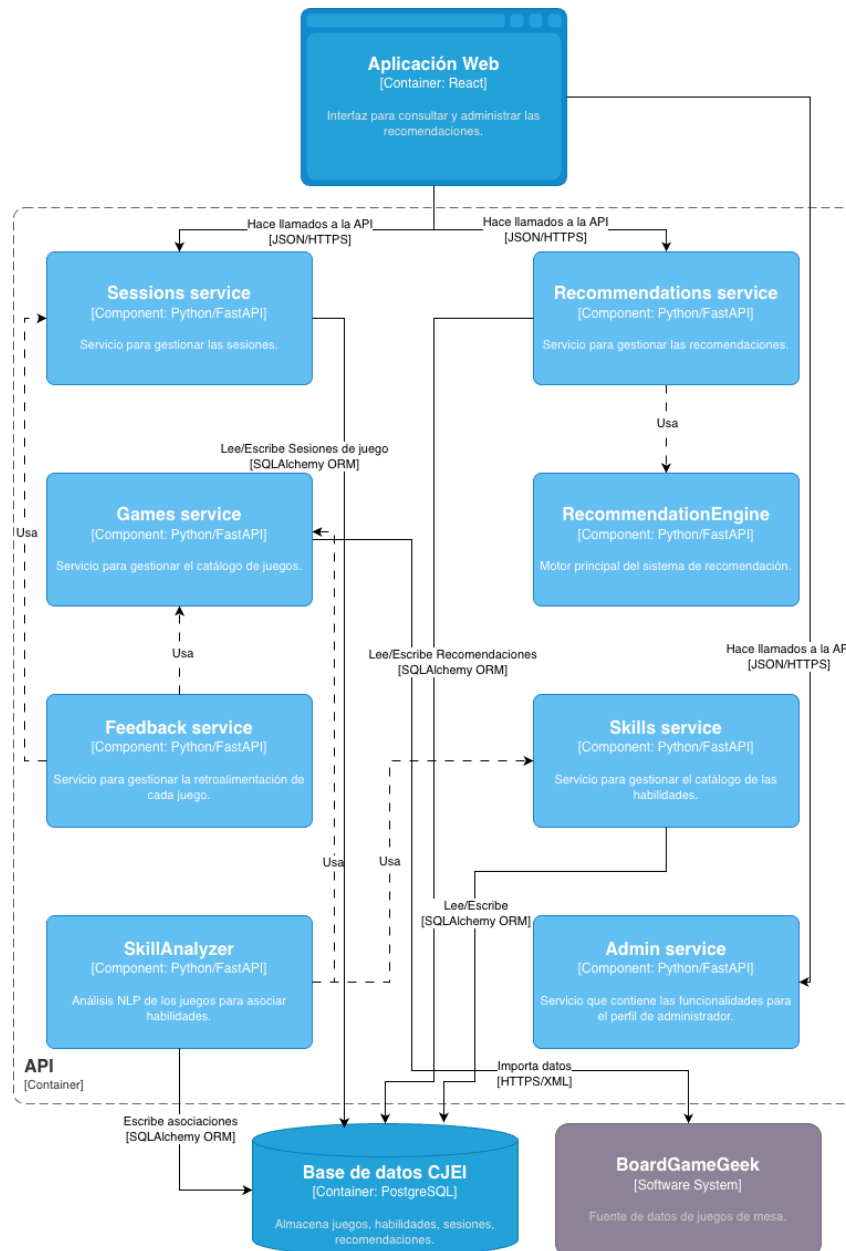


Figura A.3: Diagrama de Componentes - Nivel 3 del modelo C4

## **Anexo B: Diagrama de Secuencia - Flujo de Generación de Recomendaciones**

El diagrama de secuencia ilustra el flujo completo de interacciones entre componentes durante el proceso de generación de recomendaciones. Muestra cómo el Asesor Pedagógico ingresa un perfil de sesión, cómo el sistema valida y procesa la solicitud, cómo el motor de recomendación calcula el scoring híbrido (Skill Score, Mechanics Score, Difficulty Score, Ranking Score), y cómo se devuelve el Top-N de juegos recomendados con sus justificaciones pedagógicas.

Actores principales:

- Asesor Pedagógico: Usuario que solicita recomendaciones.
- Frontend App: Interfaz web en React.
- FastAPI Router: Enrutador de la API.
- RecommendationEngine: Motor de recomendación híbrido.
- FilterService: Servicio de filtros duros dentro del RecommendationsService.
- ScoringService: Servicio de cálculo de scores dentro del RecommendationsService.
- ExplainabilityService: Servicio de explicaciones dentro del RecommendationsService.
- PostgreSQL DB: Base de datos relacional.

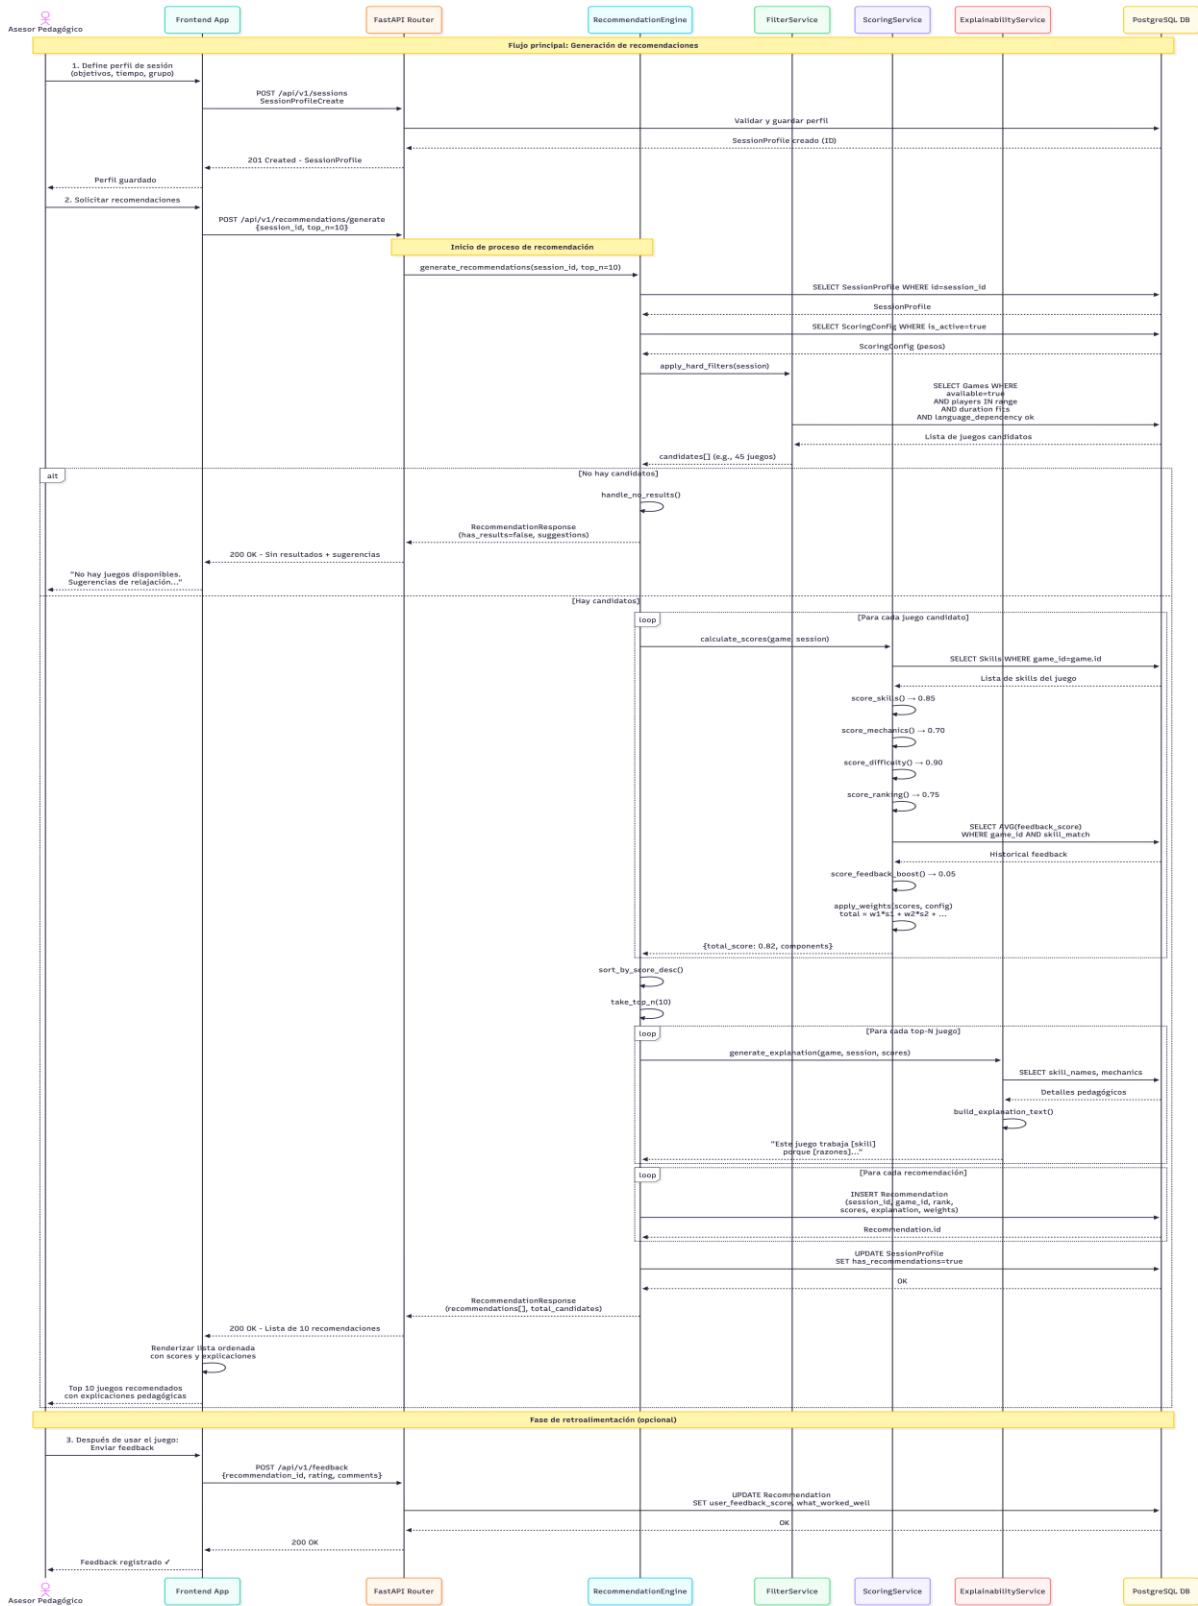


Figura B.1: Diagrama de Secuencia del proceso de generación de recomendaciones

**Pasos principales del flujo:**

1. El asesor ingresa el perfil de sesión (objetivos, restricciones operativas).
2. El frontend envía POST a `/api/v1/recommendations`.
3. El motor ejecuta validaciones de coherencia del perfil.
4. `FilterService` aplica filtros duros (disponibilidad, jugadores, tiempo, idioma).
5. `ScoringService` calcula scores por componente para cada candidato.
6. Se ordenan y seleccionan Top-N juegos.
7. `ExplainabilityService` genera justificaciones pedagógicas.
8. Se crea snapshot inmutable para trazabilidad.
9. Se devuelve JSON con recomendaciones y explicaciones.
10. El frontend renderiza la lista de juegos recomendados.

## Anexo C: Modelo de Datos - Diagrama Entidad-Relación

El Modelo Entidad-Relación (MER) documenta la estructura de la base de datos PostgreSQL del sistema. Define las entidades principales, sus atributos, tipos de datos, restricciones y relaciones.

Entidades principales:

- **games**: Catálogo de juegos de mesa con atributos normalizados (duración, complejidad, jugadores, mecánicas, idioma, ranking BGG).
- **skills**: Taxonomía jerárquica de habilidades con relación auto-referencial (`parent_id`) para construir árbol de 3 niveles.
- **game\_skills**: Tabla de asociación many-to-many entre juegos y habilidades, incluye justificación pedagógica obligatoria.
- **session\_profiles**: Perfiles de sesión con objetivos pedagógicos y restricciones operativas (tiempo, jugadores, idioma).
- **recommendations**: Resultados del motor de recomendación con scores desagregados por componente (skill, mechanics, difficulty, ranking) y posición en el Top-N.
- **audit\_logs**: Registro de trazabilidad con snapshots inmutables de cada recomendación para auditoría.
- **scoring\_configs**: Configuraciones de pesos del motor híbrido, permite personalización sin redeployment.
- **taxonomy\_snapshots**: Versionado de la taxonomía para trazabilidad histórica.

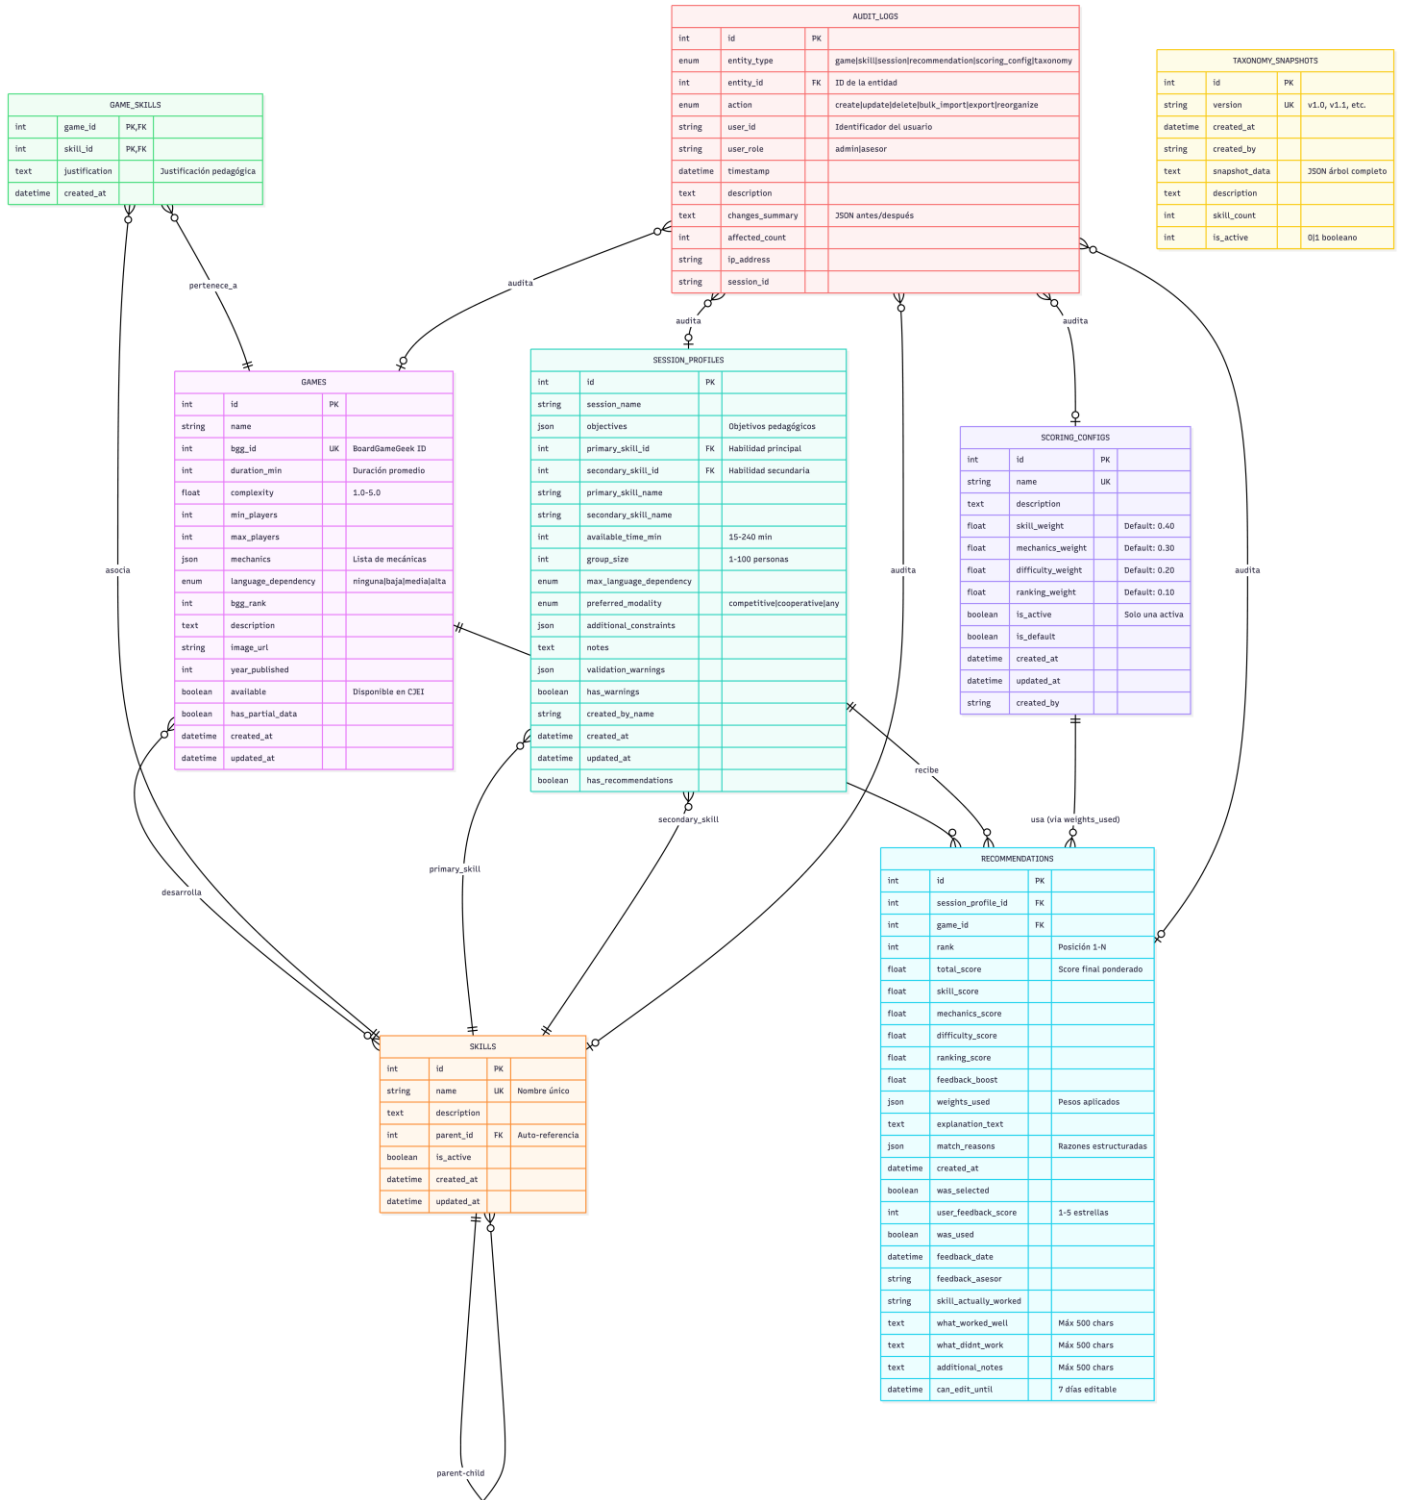


Figura C.1: Modelo Entidad-Relación de la base de datos del Sistema CJEI

### **Características del modelo:**

- **Normalización:** Tercera Forma Normal (3NF) para evitar redundancia.
- **Integridad referencial:** Todas las relaciones implementan claves foráneas con restricciones CASCADE/RESTRICT.
- **Auditoría temporal:** Campos created\_at y updated\_at en todas las entidades principales.
- **Soft delete:** Campos is\_active/available permiten desactivación lógica sin pérdida de datos históricos.
- **Escalabilidad:** Diseño permite crecimiento del catálogo (miles de juegos) y taxonomía (decenas de habilidades) sin degradación.
- **Versionado:** Snapshots de taxonomía y configuraciones para reproducibilidad de recomendaciones históricas.

Anexo 7-A. Formato I1 – Lista de verificación por tarea (checklist)

Instrucciones: registrar para cada tarea si se completó, tiempo, errores y observaciones. Marcar ayudas solicitadas.

Tarea	Completó (S/N)	Tiempo (mm:ss)	Errores críticos	Errores menores	Ayuda (S/N)	Observaciones	Evidencia (ID)
CV-01 Crear perfil							
CV-02 Generar Top-N							
CV-03 Cero resultados							
CV-04 Ver explicación							
CV-06 Comparar							
CV-07 Registrar feedback							
CV-08 Ver analíticas							

Anexo 7-B. Formato I2 – Registro de tiempos (Tprep, Trec) y eventos

Tprep: tiempo total de preparación. Trec: tiempo para obtener recomendaciones y visualizarlas. Registrar también tiempos por sub-tarea si se requiere análisis de cuellos de botella.

Sesión	Participante (código)	Tprep_baseline (min)	Tprep_prototipo (min)	$\Delta\%$ (calculado)	Trec p50/p95 (ms)	Notas

Anexo 7-C. Instrumento I3 – System Usability Scale (SUS)

Instrucciones: responder en escala 1 (totalmente en desacuerdo) a 5 (totalmente de acuerdo)

Ítem	Enunciado	Respuesta (1-5)
1	Creo que me gustaría usar este sistema con frecuencia.	
2	Encontré el sistema innecesariamente complejo.	
3	Pensé que el sistema fue fácil de usar.	
4	Creo que necesitaría el apoyo de una persona técnica para poder usar este sistema.	
5	Encontré que las diferentes funciones del sistema estaban bien integradas.	
6	Pensé que había demasiada inconsistencia en este sistema.	
7	Me imagino que la mayoría de las personas aprenderían a usar este sistema muy rápidamente.	
8	Encontré el sistema muy engorroso de usar.	
9	Me sentí muy confiado(a) usando el sistema.	
10	Necesité aprender muchas cosas antes de poder empezar a usar este sistema.	

Cálculo SUS (para análisis): convertir respuestas de ítems impares (1,3,5,7,9) restando 1; convertir ítems pares (2,4,6,8,10) como 5 – respuesta; sumar y multiplicar por 2,5. Registrar el resultado final 0–100.

Anexo 7-D. Instrumento I4 – TAM (utilidad percibida y facilidad de uso percibida)

Instrucciones: responder en escala 1 (totalmente en desacuerdo) a 5 (totalmente de acuerdo) Los ítems se adaptan al contexto CJEI y se enfocan en el uso del prototipo para preparar sesiones con juegos.

Código	Enunciado	Respuesta (1-5)
PU1	El sistema mejora mi desempeño al preparar sesiones con juegos de mesa.	
PU2	El sistema incrementa mi productividad al identificar juegos adecuados al contexto.	
PU3	El sistema facilita seleccionar juegos alineados con objetivos y habilidades.	
PU4	Considero que las recomendaciones aportan valor al proceso del CJEI.	
PEOU1	Aprender a usar el sistema me resultó fácil.	
PEOU2	Interactuar con el sistema es claro y comprensible.	
PEOU3	Es fácil para mí obtener recomendaciones y entender por qué se sugieren.	
PEOU4	En general, el sistema es fácil de usar.	

Anexo 7-E. Instrumento I5 – Entrevista semiestructurada (guion)

Guion sugerido para capturar verbatim y comprender aceptación, confianza y oportunidades de mejora.

1. ¿En qué medida las recomendaciones se ajustaron al contexto de la sesión que definió? ¿Por qué?
2. ¿Qué tan claras fueron las explicaciones del sistema? ¿Qué información le generó más confianza o más duda?
3. ¿En qué parte del flujo sintió más fricción o incertidumbre (crear sesión, interpretar restricciones, comparar, registrar feedback)?
4. ¿Qué haría diferente en el prototipo para que encaje mejor con el proceso real del CJEI?
5. Si tuviera que decidir hoy, ¿en qué casos usaría el prototipo y en cuáles preferiría el proceso manual? ¿Por qué?
6. ¿Qué datos o campos considera críticos para mejorar la precisión de la recomendación (mecánicas, complejidad, idioma, disponibilidad, otros)?
7. ¿Qué tan útil considera el registro de retroalimentación y las analíticas para preservar conocimiento institucional?
8. Observaciones finales: sugerencias de mejora, funcionalidades deseadas, barreras de adopción.