



**PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR
SEDE IBARRA**

ESCUELA DE INGENIERÍA

INFORME FINAL DEL PROYECTO

TEMA:

“Modelo de agente adaptativo al contexto para ofrecer recursos didácticos”.

PREVIO A LA OBTENCIÓN DEL TÍTULO DE

Ingeniero en Sistemas

LÍNEA DE INVESTIGACIÓN:

Ingeniería en Software, Innovación y Emprendimiento en TICs.

AUTOR:

BRYAN GUSTAVO ARELLANO CUZCO

ASESORA:

PHD. DULCE MILAGRO RIVERO ALBARRÁN


IBARRA - NOVIEMBRE 2018

Ibarra, 27 de noviembre de 2018

PhD. Dulce Milagro Rivero Albarrán
ASESORA

CERTIFICA:

Haber revisado el presente informe final de investigación, el mismo que se ajusta a las normas vigentes en la Escuela de Ingeniería, de la Pontificia Universidad Católica del Ecuador Sede Ibarra (PUCESI); en consecuencia, autorizo su presentación para los fines legales pertinentes.


(f)

PhD. Dulce Milagro Rivero Albarrán

C.C.: 175760896-1

PÁGINA DE APROBACIÓN DEL TRIBUNAL

El jurado examinador, aprueba el presente informe de investigación en nombre de la Pontificia Universidad Católica del Ecuador Sede Ibarra (PUCESI):

(f): 

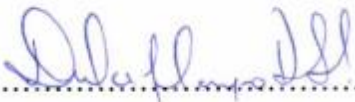
Mgs. Galo Hernán Puetate

C.C.: 040137578-1

(f): 

Mgs. Diego Baroja

C.C.: 100240206-1

(f): 

PhD. Dulce Milagro Rivero

C.C.: 175760896-1

ACTA DE CESIÓN DE DERECHOS

Yo Bryan Gustavo Arellano Cuzco, declaro conocer y aceptar la disposición del Art. 165 del Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, que manifiesta textualmente: “Se reconoce facultad de los autores y demás titulares de derechos de disponer de sus derechos o autorizar las utilizaciones de sus obras o prestaciones, a título gratuito u oneroso, según las condiciones que determinen. Esta facultad podrá ejercerse mediante licencias libres, abiertas y otros modelos alternativos de licenciamiento o la renuncia”.

Ibarra, 27 de noviembre de 2018

f):

Bryan Gustavo Arellano Cuzco

C.C.: 172753963-5



AUTORÍA

Yo, Bryan Gustavo Arellano Cuzco, portador de la cédula de ciudadanía N° 172753963-5, declaro que la presente investigación es de total responsabilidad del (los) autor (es), y eximo expresamente a la Pontificia Universidad Católica del Ecuador Sede Ibarra de posibles reclamos o acciones legales.

f):

Bryan Gustavo Arellano Cuzco

C.C.: 1727539635



A handwritten signature in blue ink, appearing to be 'Bryan Gustavo Arellano Cuzco', written over the stamp.

CERTIFICACIÓN ANTIPLAGIO

Yo Dulce Milagro Rivero Albarrán, declaro que luego del proceso de revisión en el sistema antiplagio URKUND el porcentaje de similitud del trabajo de titulación denominado: **MODELO DE AGENTE ADAPTATIVO AL CONTEXTO PARA OFRECER SUGERENCIAS DE RECURSOS DIDÁCTICOS**, es del (5%), de acuerdo al documento D44593626.

En base a lo anterior, considero que el trabajo de titulación NO SÍ cumple los requisitos de originalidad y autenticidad, de acuerdo con los requisitos establecidos por la ley.

Ibarra, 26 de noviembre de 2018



Dra. Dulce Milagro Rivero A.
C.I. 1757608961



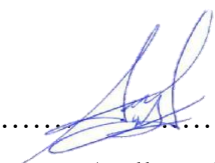
DECLARACIÓN y AUTORIZACIÓN

Yo: Bryan Gustavo Arellano Cuzco, con CC: 172753963-5, autor del trabajo de grado intitulado: “Modelo de agente adaptativo al contexto para ofrecer sugerencias de recursos didácticos”, previo a la obtención del título profesional de Ingeniería en Sistemas, en la Escuela de Ingeniería.

1.- Declaro tener pleno conocimiento de la obligación que tiene la Pontificia Universidad Católica del Ecuador Sede- Ibarra, de conformidad con el artículo 144 de la Ley Orgánica de Educación Superior de entregar a la SENESCYT en formato digital una copia del referido trabajo de graduación para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.

2.- Autorizo a la Pontificia Universidad Católica del Ecuador Sede Ibarra a difundir a través de sitio web de la Biblioteca de la PUCESI el referido trabajo de graduación, respetando las políticas de propiedad intelectual de Universidad.

Ibarra, 27 de noviembre de 2018

(f.).....
Bryan Gustavo Arellano Cuzco

C.C. 172753963-5



AGRADECIMIENTO

A todas las personas quienes me han brindado apoyo, y dado aliento para poder culminar el proyecto, mi más sincero agradecimiento.

A mi asesora PhD. Dulce Rivero, por brindarme el tiempo y apoyo necesario en el desarrollo de la tesis.

Bryan Gustavo Arellano Cuzco

ÍNDICE

RESUMEN	1
ABSTRACT.....	2
INTRODUCCIÓN	3
CAPÍTULO I	6
ESTADO DEL ARTE	6
1.1 Modelo de educación tradicional en Ecuador	6
1.1.1 Modelo educativo PUCE-SI	8
1.2 Estilos de aprendizaje	10
1.3 E-Learning.....	12
1.3.1 Web basada en e-Learning.....	14
1.3.2 Objetos de aprendizaje, estándares y especificaciones en sistemas e-Learning ...	15
1.3.2.1 Objetos de aprendizaje	15
1.3.2.2 Estandarización de objetos de aprendizaje	16
1.3.2.3 Especificaciones de objetos de aprendizaje en e-Learning	18
1.4 Personalización y adaptación en e-Learning	19
1.5 Técnicas de recomendación en e-Learning	20
1.6 Agentes y sistemas multi agentes	22
1.7 Ambientes inteligentes.....	23
1.7.1 Agentes en ambientes inteligentes e-Learning	23
1.8 Algoritmos de filtrado híbrido-mixto para recomendación de contenidos	24
1.8.1 Similitud de coseno	26
CAPÍTULO II	28
MATERIALES Y MÉTODOS	28
2.1 Marco metodológico	28
2.2 Análisis del contexto de asignación de recursos en la PUCE-SI	28
2.3 Especificación del test para la identificación de estilos de aprendizaje	33
2.4 Análisis del agente recomendador en ambientes inteligentes de enseñanza	36
2.5 Casos de uso del agente	37
2.6 Metodología del diseño	42
2.7 Diseño del agente recomendador.....	43
2.7.1 Servicios REST (Representational State Transfer)	44
2.7.2 Agente recomendador.....	49

2.7.2.1	Generador de matrices	50
2.7.2.2	Motor de recomendaciones	53
2.7.2.2.1	Filtro colaborativo	54
2.7.2.2.2	Filtro basado en contenido	56
2.7.2.2.3	Filtro híbrido	58
2.7.2.3	Despliegue de recomendaciones	58
2.7.3	Escenario de pruebas	59
CAPÍTULO III		61
RESULTADOS		61
3.1	Pruebas unitarias	61
3.1.1	Pruebas de generador de matrices	61
3.1.2	Pruebas de motor de recomendación	62
3.1.2.1	Pruebas de filtro colaborativo	62
3.1.2.2	Pruebas de filtro basado en contenido y filtro colaborativo	64
3.2	Pruebas de integración en el escenario de prueba	65
CAPÍTULO IV		75
CONCLUSIONES		75
4.1	Conclusiones	75
CAPÍTULO V		78
RECOMENDACIONES		78
5.1	Recomendaciones	78
BIBLIOGRAFÍA		79
ANEXOS		83

INDICE DE FIGURAS

Figura 1: Representación de los procesos de enseñanza tradicional según Llerena (2016)..	8
Figura 2: Representación de procesos de la planificación del syllabus de la PUCE-SI (2012)	9
Figura 3: Algoritmo de filtrado híbrido-mixto.....	25
Figura 4: Tabla comparativa de valores de MAE y porcentaje	26
Figura 5: Promedio de recompensas acumuladas a lo largo del tiempo	27
Figura 6: Elección de recursos didácticos para una clase.....	29
Figura 7: Definición de criterios para elección de recursos didácticos	30
Figura 8: Búsqueda de recursos	30
Figura 9: Disposición de recursos didácticos	31
Figura 10: Elección de recursos didácticos para actividades.....	31
Figura 11: Definición de contexto de actividades de aprendizaje	32
Figura 12: Resumen de agrupaciones de items en ILS	33
Figura 13: Resultados de ILS.....	33
Figura 14: Conjunto de preguntas de estilos de aprendizaje de interés.....	35
Figura 15: Emparejamiento de preguntas	35
Figura 16: Cadena de valor del agente recomendador	37
Figura 17: Casos de uso de agente recomendador	38
Figura 18: Diagrama de actividades de agente recomendador	39
Figura 19: Tarea de composición de matrices	40
Figura 20: Aplicación de filtros de recomendación	40
Figura 21: Filtrado de OA.....	41
Figura 22: Presentación de OA	41
Figura 23: Diagrama de componentes de modelo de agente recomendador	44
Figura 24: Modelo relacional de datos para repositorio de OA.....	45
Figura 25: Ejemplo de indicadores de perfil de estudiante	47
Figura 26: Ejemplo de objeto de aprendizaje	47
Figura 27: Ejemplo de ratings de OA.....	48
Figura 28: Componentes del agente recomendador	49
Figura 29: Clases de MatrixGenerator	50
Figura 30: Matriz de perfil de estudiante.....	50
Figura 31: Matriz de ratings de OA	51
Figura 32: Matriz de OA	52
Figura 33: Clases de RecommenderEngine	53
Figura 34: Matriz rating usuario-item	54
Figura 35: Matriz ítem-a-ítem.....	55
Figura 36: Clase de filtro colaborativo	56
Figura 37: Clase de filtro basado en contenido.....	57
Figura 38: Clase de filtro híbrido	58
Figura 39: Interfaz de visualización de recomendaciones	58
Figura 40: Escenario de pruebas - Usuarios registrados	59
Figura 41: Escenario de pruebas - Usuario nuevos.....	60
Figura 42: Resultados de cálculos para matriz ítem-a-ítem.....	63

Figura 43: Predicciones de ratings generadas por el filtro colaborativo	63
Figura 44: Resultados de filtro híbrido.....	64
Figura 45: Resultados de recomendaciones para "Sistemas de numeración: decimal, binario, hexadecimal"	66
Figura 46: Resultados de recomendaciones para "Sistemas operativos, definición"	67
Figura 47: Resultados de recomendaciones para "Ecuaciones trigonométricas"	68
Figura 48: Resultados de recomendaciones para "Ecuaciones".....	69
Figura 49: Resultados de recomendaciones para "Geometría analítica"	70
Figura 50: Promedio de recomendaciones para "Sistemas operativos, definición"	71
Figura 51: Promedio de recomendaciones para "Sistemas de numeración: decimal, binario, hexadecimal".....	72
Figura 52: Promedio de recomendaciones para "Ecuaciones"	73
Figura 53: Promedio de recomendaciones para "Ecuaciones trigonométricas"	73
Figura 54: Promedio de recomendaciones para "Geometría analítica"	74

RESUMEN

La presente investigación se basó en el desarrollo de un modelo de agente recomendador, que tiene como fin presentar recursos didácticos que se adecuen a las características de aprendizaje de cada estudiante de la Pontificia Universidad Católica del Ecuador sede Ibarra, esto significa, que los recursos se adaptan al perfil del estudiante, de una manera que él pueda asimilar nueva información de una forma más adecuada; en este contexto se inicia una transformación en la educación tradicional, llevándola hacia una instrucción personalizada a través del uso de distintos agentes inteligentes que trabajen en conjunto en un ambiente inteligente para brindar una experiencia agradable a los alumnos.

El proyecto estuvo enmarcado en el tipo de investigación documental y aplicada, fundamentada en el análisis de fuentes de información de técnicas de recomendación híbridas que emplean filtros basados contenido y modelos colaborativos. Obteniendo como resultado un agente desarrollado bajo la metodología ágil XP y el lenguaje de programación PHP. Como efecto se obtuvo un agente que emplea servicios REST para obtener y generar información, y que utiliza un conjunto de diferentes matrices que contienen los indicadores cuantitativos y cualitativos del perfil del estudiante, los objetos de aprendizaje o recursos didácticos y las valoraciones de los objetos de aprendizaje, para inferir las recomendaciones de cada filtro, las cuales posteriormente se mostrarán al estudiante.

Finalmente, a través de un escenario de pruebas, se pudo concluir que el desempeño del agente recomendador es acertado, ya que proporciona recomendaciones de objetos de aprendizaje que se ajustan a las características de aprendizaje de cada perfil de estudiante con el que se realizaron las pruebas.

Palabras clave: Objetos de aprendizaje, Agente recomendador, Instrucción personalizada, Técnicas de recomendación híbridas, Ambiente inteligente.

ABSTRACT

The present investigation was based on the development of a model of recommending agent, which aims to present didactic resources that are adapted to the learning characteristics of each student of the Pontifical Catholic University of Ecuador Ibarra headquarters, this means that resources Adapted to the profile of the student. in this context a transformation in traditional education begins, leading to personalized instruction, through intelligent agents, we work in an intelligent environment to provide a pleasant experience for students.

The project was framed in the type of documentary and applied research, fundamentally in the analysis of information sources of hybrid techniques that use content filters and collaborative models. Obtaining as result an agent developed under the agile XP methodology and the PHP programming language. As effect, an agent was obtained that uses REST services to obtain and generate information, and to use a set of different matrices that provide the quantitative and qualitative indicators of the student's profile, learning objects and didactic resources and the qualifications of the objects of learning, to infer the recommendations of each filter,

Finally, through a testing scenario, it is possible to conclude with the performance of the recommending agent is correct, the recommendations of the learning objects that conform to the learning characteristics of each student profile have been found.

Keywords: Learning objects, Recommended agent, Personalized instruction, Hybrid recommendation techniques, Intelligent environment.

INTRODUCCIÓN

Los avances en las tecnologías de la información, especialmente con la expansión de la red Internet han cambiado la forma en la que se percibe, aprecia y aprende la realidad, dado que los límites que antes se imponían por la distancia, el tiempo y la cultura han sido sobrepasados (Collis, 1996; Verdejo & Gordon, 1998). En ese sentido, la constante evolución de la tecnología ha cambiado la manera en la que las personas viven y se desenvuelven en su vida cotidiana en aspectos como: educación, trabajo, entretenimiento, entre otros.

La informática como herramienta de apoyo en la educación ha dado origen al “e-Learning”, el cual consiste en una educación y capacitación basada en el uso de nuevas tecnologías que permiten el acceso a la formación en línea, de forma interactiva y a veces personalizada a través de Internet u otros medios electrónicos (intranet, extranet, TV interactiva, CD-ROM, entre otros.) (Adom̄bent, Barth, Fischer, Richter, & Rieckmann, 2014).

Dada la naturaleza de los sistemas e-Learning han surgido distintos entornos de aprendizaje virtuales, que permiten gestionar el proceso académico, permitiendo a los docentes crear materiales pedagógicos para manejar sus cursos virtuales. Sin embargo, este material sólo está disponible para una determinada plataforma y asignatura, lo que impide que el mismo sea reutilizable y su tiempo de uso sea limitado. Como respuesta a éste inconveniente surgen los Objetos de Aprendizaje (OA) y sus repositorios que permiten compartir y reutilizar material didáctico, utilizando arquitecturas orientadas a servicios (SOA) y basándose en estándares como SCORM para el diseño estructural de los OA; de esta manera se asegura su interoperabilidad, durabilidad y reusabilidad.

En los últimos años, la adaptación y personalización de los OA, ha sido un nuevo reto para la investigación y desarrollo de los sistemas e-Learning. La personalización de los OA es uno de los aspectos que ha sido ampliamente estudiados, dando como resultado diferentes campos de investigación, tales como: identificación del estilo de aprendizaje¹, sistemas

¹ Identificación del estilo de aprendizaje, personalización del sistema basado en estilos de aprendizaje identificados de cada usuario.

recomendadores², adaptación de enlace³ y agentes pedagógicos personalizados⁴ (Klašnja-Milićević A. , Vesin, Ivanović, & Budimac, E-Learning personalization based on hybrid recommendation strategy and learning style identification., 2011). En este sentido los sistemas de recomendación es el punto clave para este trabajo de investigación.

Los sistemas recomendadores pueden ser parte del comportamiento de los agentes inteligentes en entornos educativos. El uso de agentes inteligentes surge con el objetivo de motivar y guiar a los estudiantes a través del proceso de aprendizaje en los sistemas e-Learning y sistemas de tutoría; dichos agentes pueden definirse como entidades de software autónomas, que poseen varios grados de inteligencia, capaces de exhibir comportamientos proactivos y reactivos para satisfacer sus objetivos de diseño (Bădică, Zoran , Hans-Dieter , & Mirjana , 2011).

Un campo de investigación, en el que la teoría de agencia ha realizado aportes es el de los ambientes inteligentes. Actualmente es la era en la cual abundan ambientes tecnológicamente enriquecidos, que proactivamente apoyan a las personas en su vida diaria; a esta área de la computación se le conoce como Inteligencia Ambiental o AmI. Los AmI tienen como objetivo razonar con información acumulada y seleccionar las acciones a tomar que sean más adecuadas para cada usuario con el fin de beneficiarlo, de esta manera varios dispositivos autónomos son puestos al servicio de las personas; dichos dispositivos se comunican entre ellos, para en conjunto poder trabajar y adaptarse a las necesidades de sus usuarios, proveyendo de soluciones que se adapten a las distintas necesidades de los usuarios, permitiendo facilitar sus actividades diarias, a través del análisis de la información que se le provee.

Una de las principales particularidades de la inteligencia ambiental es que puede llegar a reforzar o amplificar las capacidades cognitivas de las personas, dependiendo del área en la que se desarrolle; entre los campos de aplicación se pueden mencionar los siguientes: casas

² Sistemas recomendadores, sistemas usados para recomendar materiales educativos apropiados para el estudiante y seleccionar las rutas óptimas a través de los materiales de aprendizaje.

³ Adaptación de enlace, sistema que modifica la apariencia o disponibilidad de un enlace en una página web de un curso, mostrándole al alumno si el enlace conduce a nueva información interesante, información para la que no está listo o información que no aporta nada nuevo.

⁴ Agentes pedagógicos personalizados, sistemas e-Learning equipados con distintos agentes que facilitan la calidad de entrega de temas y la evaluación de los conocimientos adquiridos .

inteligentes, servicios de salud, espacios de trabajo y entornos educativos, es decir, esta tecnología cambia la forma en la que se percibe el ambiente y la manera en la que se interactúa con él.

El presente trabajo se centra en la investigación de distintas técnicas aplicadas en sistemas recomendadores e-Learning para ofrecer materiales didácticos (OA) ubicados en un repositorio virtual, con el objetivo de mejorar algunos procesos de aprendizaje. Específicamente, se propone desarrollar el prototipo de un agente inteligente que proporcione recomendaciones de material didáctico aplicando las principales técnicas aplicadas en sistemas de recomendación e-Learning, Además, será capaz de interactuar con otros agentes de la plataforma inteligente para que pueda integrarse en la plataforma multi agentes para Salones Inteligentes (SaI).

CAPÍTULO I

ESTADO DEL ARTE

1.1 Modelo de educación tradicional en Ecuador

El Art. 27 de la Constitución de Ecuador del año 2008 establece que “*la educación se centrará en el ser humano y garantizará su desarrollo holístico...*”, es decir, una educación centrada en el desarrollo de la persona en el sentido más completo posible, anima a los alumnos a dar lo mejor de sí y los capacita para sacar el mejor provecho de las experiencias de la vida y alcanzar sus metas (Forbes, 2003). Ésta educación sigue teniendo como base el modelo tradicional de enseñanza, donde el profesor es el especialista que domina la materia y la transmite de modo que los alumnos la lleguen a comprender como él mismo. (Mena, 2012).

En el proceso tradicional de aprendizaje, el profesor asume o toma el rol de experto o autoridad de la materia, de esta manera transmite su conocimiento hacia los alumnos, los cuales son establecidos como recipientes pasivos de información. La información, por lo general, se transmite a través de exposiciones, por medio de una comunicación unidireccional a un grupo de alumnos, además el docente distribuye recursos didácticos a los estudiantes, con el fin de que realicen actividades o para emplearlos en su autoeducación. Este proceso conlleva a un aprendizaje individual y de competencia en el cual los alumnos absorben, transcriben y memorizan información para su posterior uso en pruebas o exámenes, en busca de obtener la respuesta correcta para tener éxito; siendo el docente su único evaluador (Llerena , 2016).

El docente por lo general aplica distintas evaluaciones acorde a las circunstancias y tiempo para distinguir los resultados académicos de los estudiantes, en éstas evaluaciones se pueden distinguir tres etapas significativas (Paucar & Alfredo, 2015):

- **Evaluación diagnóstica (inicial):** Utilizada antes de iniciar el proceso de enseñanza-aprendizaje, para verificar el nivel de los estudiantes.

- **Evaluación formativa (intermedia, continua o procesal):** Se basa en la recolección de información a través de pruebas, ejercicios, tareas, entre otros; tanto del resultado como del proceso mismo.
- **Evaluación sumativa (final):** Realizada al final del proceso de enseñanza-aprendizaje, para verificar si se han cumplido con los objetivos educacionales planteados y en qué medida fueron captados por cada estudiante.

A partir de este punto, se obtiene una visión más lógica de lo que un proceso de aprendizaje tradicional conlleva y cuáles son los elementos que intervienen en él, ciertamente el profesor observa a los alumnos como una unidad a la cuál debe ofrecer información para que éstos la asuman independientemente de sus capacidades. Además de brindarles un conjunto de recursos didácticos, los estudiantes pueden aumentar o mejorar su conocimiento, utilizando diferentes medios de información, con el objeto de que ellos seleccionen las fuentes a las que mejor se adaptan.

Por otro lado, cada estudiante debe adaptarse al recurso que el docente le proporciona, en lugar de que el recurso sea compatible a sus capacidades y necesidades cognitivas, lo cual en cierta medida lleva al estudiante a buscar recursos más adecuados a él o inclusive llegue a ignorar el recurso que se le ha dispuesto. La Figura 1 muestra el diagrama de procesos obtenido a través del análisis de la investigación de Llerena realizada en 2016, en el cual se detalla el comportamiento del docente y los alumnos en el transcurso del aprendizaje tradicional.

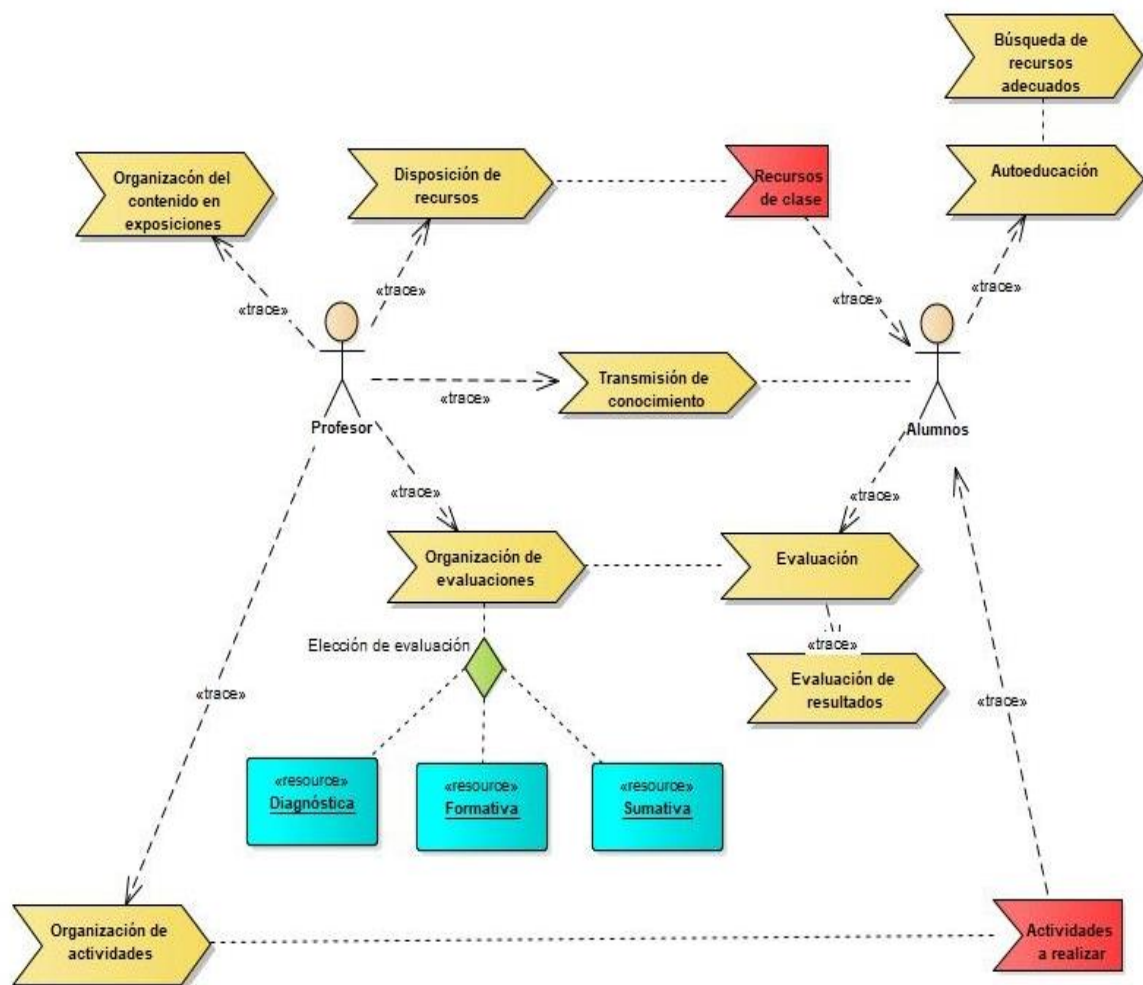


Figura 1: Representación de los procesos de enseñanza tradicional según Llerena (2016)

Fuente: Bryan Arellano

1.1.1 Modelo educativo PUCE-SI

“Como sede de la Pontificia Universidad Católica del Ecuador, el modelo educativo empleado, parte del pensamiento del fundador de las misiones identes, Fernando Rielo” (PUCE-SI, 2012, pág. 15); en el cuál se implica una visión global, de tal manera que la pedagogía no puede reducirse solamente a una metodología, sino que debe incluir una perspectiva del mundo y una visión de la persona humana ideal que se pretende formar (ITESO, 1993). El proceso de aprendizaje se enfoca en el alumno y el desarrollo de sus competencias (actitudes, habilidades y conocimiento), a través de aprendizajes significativos que le permiten desarrollarse tanto como persona íntegra, así como un profesional de alta calidad.

“Operativamente todo profesor antes de iniciar el semestre, debe entregar en las secretarías respectivas, el programa de cada materia, módulo o área a su cargo, en la que consten el objetivo general, las competencias, los contenidos, estrategias didácticas, los resultados de aprendizaje, la bibliografía, así como los sistemas de evaluación; lo cual debe estar aprobado por el Consejo de la Unidad y las fechas en las que los estudiantes deberán rendir las pruebas”, dicha planificación se plantea en un documento denominado Syllabus (PUCE-SI, 2012, pág. 21); esta metodología operativa se contempla en la Figura 2, la cual muestra el diagrama de procesos que el docente realiza para su plan académico, fundamentado en el análisis de la planificación del syllabus y pláticas con docentes de la institución.

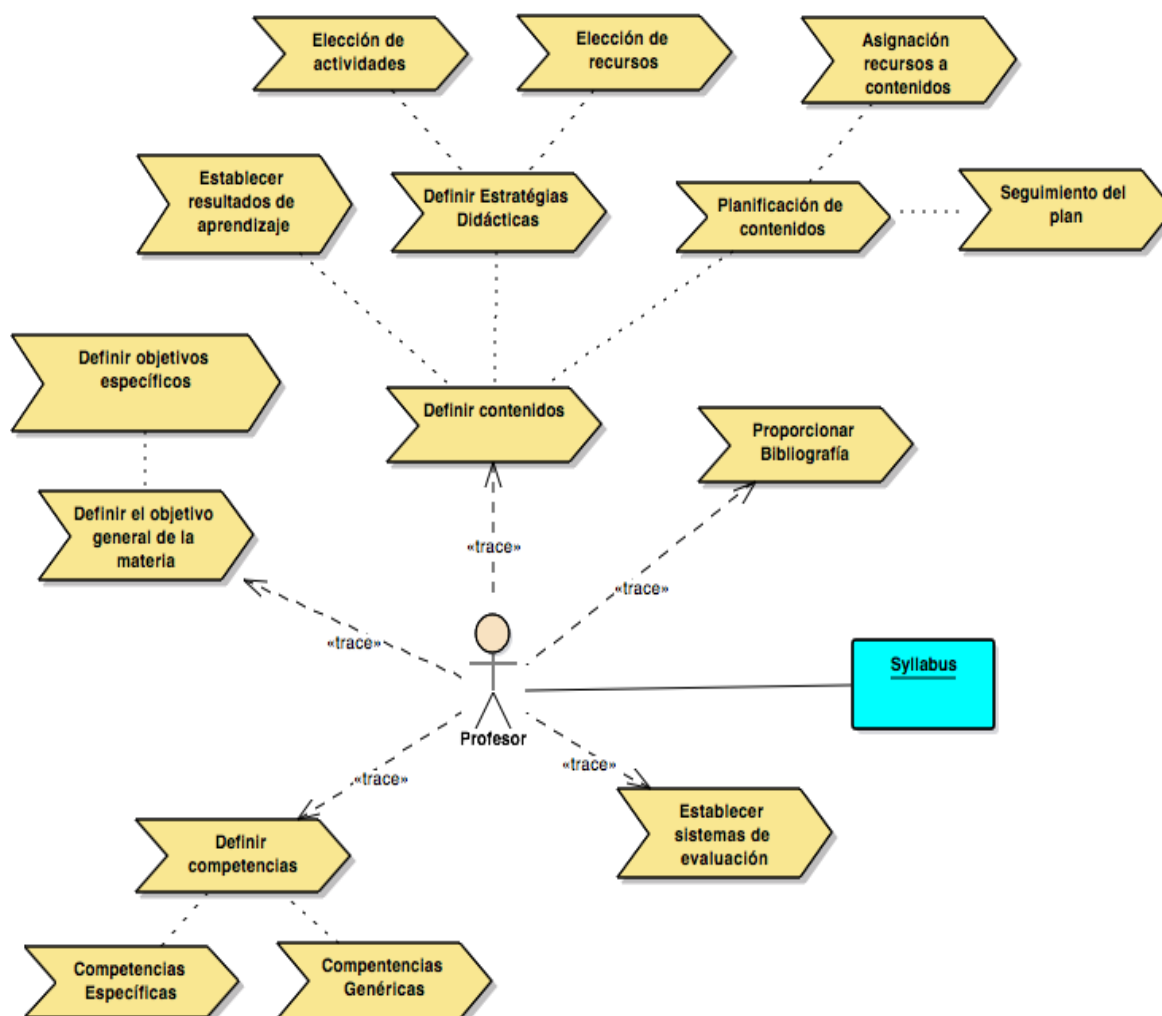


Figura 2: Representación de procesos de la planificación del syllabus de la PUCE-SI (2012)

Fuente: Bryan Arellano

Como se puede observar en la Figura 2, el docente lleva a cabo una planificación meticulosa, en la cual plantea cuáles son los contenidos a impartir, así como los objetivos que pretende

que sus estudiantes alcancen, para obtener como resultado una planificación total del semestre (Syllabus). Dentro de este proceso, el docente tiene que considerar los recursos que debe proveer a sus alumnos como material de apoyo, con el objeto de cumplir sus objetivos, estos recursos deben estar dirigidos a conseguir la formación del alumno desde todas las dimensiones de su ser, siendo las que estén a su alcance y puedan ser usadas correctamente acorde a las competencias que se quieren conseguir (PUCE-SI, 2012, pág. 22). Cabe recalcar que estos recursos se disponen de tal manera que, uno o varios recursos son proporcionados para todos los estudiantes por igual, es decir, que como consecuencia de la influencia modelo de aprendizaje tradicional, las capacidades y estilos cognitivos son dejados de lado para centrarse en un objetivo general para todos los estudiantes; como consecuencia el estudiante debe adaptarse al recurso que se le disponga.

1.2 Estilos de aprendizaje

La educación actual ha adoptado un nuevo enfoque en el proceso de aprendizaje, ya que enfatiza cuál es el rol que tiene el estudiante en él; de esta manera el proceso de la recepción y procesamiento de información se ajustan a las necesidades personales, así como a los objetivos de cada estudiante.

El primer paso, es la identificación del grado de preferencia que tiene cada estudiante para ingresar y procesar información al cerebro, es decir, el modo particular o la manera en que cada uno aprende algo nuevo; esto implica identificar el conjunto métodos o estrategias usadas para asimilar nueva información, denominados estilos de aprendizaje.

Dada la amplia gama de investigaciones realizadas acerca del tema, existen distintos tipos de clasificaciones realizadas por distintos autores, de entre los cuales destacan (Segarra Morales, 2017):

- **Guinder y Blander:** Consideran que para aprender el cerebro emplea tres sistemas: visual, auditivo, kinésico.
- **Honey y Alonso:** Utilizan una clasificación en función de cómo las personas procesan la información para aprender, la cual puede ser: activo, reflexivo, teórico, pragmático.

- **David Kolb:** Parte de la manera en la que las personas de manera habitual procesan la información, estableciendo cuatro estilos: asimilador, divergente, convergente, acomodador.
- **Felder y Silverman:** Parten de las preferencias que tiene cada sujeto para procesar y asimilar información, es decir, se refieren a cómo aprende cada estudiante de manera individual, segmentando el grado de preferencias en cuatro ejes: sensorial-intuitivo, visual-verbal, activo-reflexivo, global-secuencial.
- **Ned Hermann:** El modelo que propone se basa en el conocimiento del funcionamiento cerebral, haciendo una analogía entre las regiones del cerebro y los cuatro puntos cardinales, de tal manera que se obtiene la siguiente clasificación: racionales, cuidadosos, experimentales, emotivos.

Se han mencionado los distintos puntos de vista de algunos autores, pero la clasificación según Felder y Silverman es la más adecuada para generar un modelo lógico capaz de integrarse a un componente informático como el caso de un agente inteligente; debido a que tiene énfasis en los grados de preferencias de cada individuo con respecto a sus métodos de aprendizaje. Esto se debe a que la segmentación que utiliza facilita una evaluación cuantitativa para determinar las tendencias de un alumno con respecto a los estilos de aprendizaje que le ayudan a la asimilación de información. A continuación, una breve explicación de cada segmento:

- Sensorial-intuitivo:** Hace referencia a la manera en la que los sentidos y la mente perciben su entorno, de tal manera que los estudiantes relacionan lo aprendido con hechos para verificar que la información recibida es real; como consecuencia los estudiantes sensitivos están orientados a hechos y procedimientos, por el contrario, alguien intuitivo se orienta hacia las teorías y significados.
- Visual-verbal:** El aprendizaje se basa en la representación visual de la información tales como imágenes, dibujos, esquemas, entre otros; por otro lado, el estilo verbal se basa en la representación de la información mediante palabras escritas o de manera oral.

- c) **Activo-reflexivo:** La aplicación de conocimientos hacia la resolución de problemas para posteriormente integrar nueva información a través de la experiencia junto a otros, es lo que define a un estudiante activo; por el contrario, alguien reflexivo tiene tendencia hacia el trabajo individual con el fin de interiorizar acerca de la información nueva o de un tema en particular.

- d) **Global-secuencial:** Un estudiante con entendimiento global parte de una concepción sistémica y conocimiento general, por otro lado, alguien secuencial tiene un entendimiento parcial y se orienta hacia un aprendizaje que presente una progresión ordenada y lógico, es decir, lineal.

1.3 E-Learning

El término de *e-Learning* es relativamente nuevo ya que apareció por primera vez en 1999 durante el seminario de CBT Systems en los Ángeles (Asoke & Karmakar, 2014), junto a otros términos como “aprendizaje en línea” y “aprendizaje virtual”, esta palabra fue concebida para calificar una manera de aprendizaje basada en el uso de las nuevas tecnologías permitiendo el acceso a un entrenamiento en línea, interactivo y a veces personalizado a través de internet u otros medios electrónicos, dichos medios pueden ser discos de audio o video, televisión interactiva, dispositivos móviles e inalámbricos, entre otros; uno de los objetivos del *e-Learning* es el desarrollo de contenido de aprendizaje individualizado, entendible y dinámico en tiempo real. De igual manera el *e-Learning* puede realizarse dentro o fuera del salón de clases, en un aprendizaje combinado, es decir, un aprendizaje tradicional cara a cara junto a un aprendizaje flexible a distancia.

Por otro lado los principios y primeras formas del *e-Learning* aparecieron desde el siglo XIX (Asoke & Karmakar, 2014), ya que mucho antes de la aparición del internet se ofrecían cursos a distancia para estudiantes de distintos países, por ejemplo: el profesor Isaac Pitman enseñó taquigrafía por correspondencia en 1840, incluso sus alumnos le enviaban tareas completadas a través del servicio de correos, posteriormente él les enviaba más trabajo para que terminen (García, 1999). Sin embargo el desarrollo de máquinas capaces de ayudar en el aprendizaje ha ido evolucionando durante varios años, por ejemplo en 1926 el profesor Sidney Pressey de la Universidad del Estado de Ohio crearía una máquina de pruebas que permitía probar el conocimiento de los estudiantes a través de preguntas de selección

múltiple (Mutter, 1972), a partir de ese punto aparecieron distintos proyectos como la “máquina de enseñanza” inventada por el profesor B. F. Skinner, ésta máquina permitía administrar instrucciones programadas para los estudiantes; o PLATO (Programmed Logic Automated Teaching Operations) en 1976 la cual sería la primera computadora basada en conceptos de pruebas en línea, e-mail, salas de chats, foros, pizarra de mensajes, mensajería instantánea y juegos multijugador (Appel & Murphy, 1977). La revolución en el *e-Learning* llegaría en 1980 cuando las primeras computadoras MAC permitieron a las personas tener computadoras en sus hogares, esta posibilidad ofreció a los estudiantes una manera más fácil de adquirir nuevas habilidades y aprender sobre ciertas materias.

Posteriormente a finales de la década de los noventa algunas universidades empezaron a diseñar y desarrollar sus propios sistemas de gestión de aprendizaje (Learning Management Systems⁵), siendo hoy en día el sistema MOODLE uno de los más empleados alrededor del mundo debido a que permite realizar pruebas, intercambiar materiales de aprendizaje, comunicación entre sí de muchas maneras, monitorear el progreso, entre otras cosas. (Aranda, 2012)

Actualmente, el *e-Learning* es muy popular ya que aparece en distintas maneras y ofrece oportunidades ilimitadas a universidades, empresas e individuos en forma de aprendizaje formal e informal; básicamente esto se debe a que el *e-Learning* tiene muchas ventajas sobre el aprendizaje tradicional en un salón de clases, particularmente porque el ritmo del *e-Learning* se puede adaptar al del alumno, además de que los costos son usualmente bajos y no existen limitaciones de espacio y tiempo. Una buena alternativa al *e-Learning* regular es el combinado, el cual es una combinación del aprendizaje tradicional y el *e-Learning*, ésta forma de aprendizaje involucra una enseñanza en un salón de clases con un aprendizaje en paralelo que emplea sistemas de tutoría o sistemas de *e-Learning* (Garrison & Vaughan, 2007).

⁵ Learning Management System (LMS) software instalado generalmente en un servidor web (puede instalarse en una intranet), que se emplea para crear, aprobar, administrar, almacenar, distribuir y gestionar las actividades de formación virtual (Castro, Clarenc, de Lenz, Moreno, & Tosco, ANALIZAMOS 19 PLATAFORMAS DE E-LEARNING, 2013).

1.3.1 Web basada en e-Learning

La educación presencial está sujeta a un proceso de transformación, lo cual implica cambios en los métodos tradicionales de enseñanza, pasando de la exposición de contenidos a alumnos utilizando textos y apuntes, a la utilización de nuevos medios y actividades para el reforzamiento del aprendizaje, por ejemplo el uso de medios audiovisuales; sin embargo lo que realmente ha conllevado un cambio significativo en la educación sería la llegada de nuevas tecnologías que facilitarían la transmisión de conocimiento y ayudarían a mejorar los procesos de enseñanza y aprendizaje; una de ellas sería la Internet.

Desde 1990 el aprendizaje basado en la web se ha convertido en una rama importante de la educación, ya que ofrece, de forma virtual, un acceso ilimitado a la información, de la que el estudiante podrá generar el conocimiento necesario o requerido. Además, es un proceso de aprendizaje que involucra todos los aspectos que posee la WWW (World Wide Web) como tecnología básica y medios de comunicación.

Las características distintivas del aprendizaje basado en la web (Harsh & Sohail, 2002) son:

- Separación de profesores y alumnos,
- Uso de tecnologías web para la presentación y distribución de contenido,
- Posibilidades de comunicación bidireccional entre los alumnos y entre los alumnos y maestros

Hay una serie de elementos importantes asociados con el aprendizaje basado en la web, tales como: *e-Learning*, aprendizaje a distancia y aprendizaje personalizado. Como ya se mencionó, el *e-Learning* nació en el año 1999 y a partir de esa fecha se desarrolló un conjunto de aplicaciones de software basadas en la Web las cuales han servido para planificar, implementar y evaluar procesos de aprendizaje específicos. Estos sistemas han proporcionado al instructor herramientas que facilitan o apoyan las tareas de crear y distribuir contenidos, monitorear la participación de los estudiantes, y evaluar el aprendizaje del alumno. Además de proporcionar al alumno características interactivas como foros de discusión, chats, entre otros. (IRS, 2004). Hoy en día prácticamente cada universidad en el mundo posee una página Web en la que facilita mucha información acerca de la institución, oferta académica, servicios como matriculación en línea o consultas de horarios de clases o

calificaciones, campus virtuales, entre otras cosas; ahora bien los campus virtuales tienden a desarrollarse bajo la definición de *e-Learning* mencionada anteriormente, ya que en estos entornos el participante (estudiante o docente) puede acceder y desarrollar una serie de acciones que son propias de un proceso de enseñanza presencial; como la disposición de distintos tipos de recursos, por ejemplo libros, ejercicios, videos, entre otros., a estudiantes por parte del docente; con la finalidad de reforzar sus conocimientos.

Pero a pesar de que los entornos o plataformas usadas por los estudiantes tienden a facilitar actividades académicas, administrativas y/o sociales de los alumnos, no son sistemas que ofrezcan adaptabilidad en el momento de satisfacer las necesidades de aprendizaje debido a que los participantes o alumnos poseen distintos ritmos y estilos de aprendizaje.

Como consecuencia de los inconvenientes anteriormente mencionados los sistemas basados en *e-Learning* optan por procesos que den soporte a la personalización en el proceso de enseñanza y aprendizaje, como la identificación de estilos de aprendizaje, utilización de OA, la utilización de modelos pedagógicos, entre otros. Todo esto para darles a los alumnos una mejor experiencia de aprendizaje en las plataformas que empleen, basándose en las pautas necesarias para cada uno de ellos.

1.3.2 Objetos de aprendizaje, estándares y especificaciones en sistemas e-Learning

1.3.2.1 Objetos de aprendizaje

No existe una definición formal que describa con exactitud un OA, ya que varios autores tienen una visión distinta de lo que representan, y más aún, considerando su constante evolución y adaptación a las nuevas necesidades pedagógicas y tecnológicas; por ejemplo según el Instituto de Ingeniería Eléctrica y Electrónica (IEEE de sus siglas en inglés del *Institute of Electrical and Electronics Engineers*) es una “entidad digital o no digital, que puede ser utilizada, reutilizada y referenciada durante el proceso de aprendizaje apoyado con tecnología”, por otra parte se le considera como “elementos de un nuevo tipo instrucción de computadores que siguen el paradigma de Orientación a Objetos de Ciencias de la Computación” (Wiley, 2003), otros autores los ven como unidades o recursos, sin embargo la idea principal de los OA es que son materiales educativos diseñados y creados para

mejorar la experiencia educativa, además de poder ser reutilizados varias veces en diferentes contextos.

Dichos OA poseen características que los distinguen de otros recursos educativos, según Ceibal (2009):

- **Autocontención:** Por sí solo debe tener sentido y ser capaz de cumplir con el objetivo de aprendizaje para el cual fue creado.
- **Usabilidad:** Puede ser empleado por un grupo de usuarios específicos, para conseguir objetivos particulares con efectividad, eficiencia y satisfacción en un contexto definido.
- **Reusabilidad:** En función de las necesidades el mismo puede ser utilizado en distintos contextos con el fin de cumplir un objetivo.
- **Efectividad:** Coherencia entre propósitos y logros (objetivos de aprendizaje)
- **Accesibilidad:** Indexación para una localización y recuperación más eficiente, utilizando esquemas estándares de metadatos.
- **Portabilidad:** Pueden moverse y almacenarse en distintas plataformas de manera tal que su estructura o contenido no sufran cambios.
- **Durable, actualizable y secuenciable:** Su estructura debe permitir la integración de nuevo contenido, modificación y/o secuenciación del ya existente. En el caso de actualizaciones de software o hardware deben permanecer intactos.
- **Brevidad y síntesis:** Para alcanzar los objetivos debe emplearse el mínimo de recursos para evitar una saturación.
- **Duración:** Se recomienda una fluctuación de recorrido de entre 10 y 20 minutos.
- **Incorporar la fuente:** Inclusión de autores para evitar la infracción de derechos de autor.

1.3.2.2 Estandarización de objetos de aprendizaje

La estandarización pretende proveer de mecanismos que potencien y garanticen la interoperabilidad entre los OA, metadatos ⁶y repositorios, así como los procesos de *e-*

⁶ Metadatos, conjunto de datos que proporcionan información mínima para identificar un recurso, es decir, es la información donde se encuentran los atributos generales de un OA.

Learning, con el fin de posibilitar una reutilización efectiva de objetos entre distintos repositorios y plataformas, además de su intercambio y migración. De esta manera diferentes organismos e instituciones trabajan en conjunto para la creación de estándares internacionales que reúnan las especificaciones técnicas y de calidad que deben poseer los distintos productos y/o servicios para cumplir satisfactoriamente con las necesidades para las que han sido creados, entre los cuales se destacan las siguientes:

- **IEEE LOM (Learning Object Metadata)**

Desarrollado por el grupo de trabajo IEEE 12 (Grupo de Trabajo de Metadatos para Objetos de Aprendizaje) es un modelo conceptual estándar usado para especificar la sintaxis, semántica y describir un objeto de aprendizaje y recursos digitales similares usados para el apoyo en el aprendizaje. En el contexto de los LMS en línea apoya la reusabilidad y facilita la interoperabilidad.

- **CMI (Computer-Managed Instruction)**

Establecido por AICC (Aviation Industry CBT Committe) es una especificación sobre cómo crear contenido que se pueda comunicar la mayor cantidad de sistemas LMS, es decir, son recomendaciones para la interoperabilidad.

- **LIP-IMS (IMS-Learner Information Package)**

Especificado por IMS Global Learning Consortium, aborda la interoperabilidad de la información del estudiante entre los distintos LMS y/o sistemas basados en Internet; Su estructura se basa en: accesibilidad, actividades, afiliaciones, competencias, metas, identificaciones, intereses, calificaciones, certificaciones, licencias, relaciones, seguridad, claves y transcripciones.

- **IMS Content Packaging**

Especificación que estandariza la manera en la que se definen los recursos de aprendizaje y facilita la organización de diferentes componentes relacionados al contenido de aprendizaje; esta especificación de interoperabilidad, permite compartir contenido en un conjunto estandarizado de estructuras, es decir, un objeto de aprendizaje reúne recursos y metadatos en un medio de distribución, generalmente un archivo en formato ZIP.

- **SCORM (Sharable Content Object Reference Model)**

Desarrollado por la iniciativa ADL (Advanced Distributed Learning) bajo la solicitud del Departamento de Defensa de los Estados Unidos, como un conjunto de estándares y especificaciones para la interoperabilidad de *e-Learning*; sin embargo, su meta principal es definir la interoperabilidad, accesibilidad y reusabilidad de OA. Actualmente la mayoría de LMS utilizan el estándar SCORM, debido a que unifica estándares anteriores, de tal manera que recoge las características más destacadas de cada uno de ellos.

1.3.2.3 Especificaciones de objetos de aprendizaje en e-Learning

Las especificaciones para la creación y distribución de OA en sistemas *e-Learning* se basan principalmente en las necesidades que se quieran satisfacer. Dichas especificaciones surgen a partir del estándar que se elija como base para cumplir con el objetivo planteado, independientemente de la tecnología subyacente del entorno, sin embargo, podría suceder que una especificación no sea lo suficientemente apta para cumplir con las necesidades requeridas. Por esta razón las especificaciones como SCORM que recogen las ventajas de distintos estándares, permiten una comunicación con distintos LMS y disseminación del material de aprendizaje de una mejor manera. De esta manera SCORM se puede usar como referencia para la especificación de OA en *e-Learning*.

Según Sierra et al. (2011), el estándar SCORM se basa en 6 principios:

- **Accesibilidad:** Posibilidad de localizar y acceder a componentes instruccionales desde una locación remota y su envío a otras localizaciones.
- **Adaptabilidad:** Adaptar la enseñanza a distintas necesidades individuales u organizacionales.
- **Asequibilidad:** Aumento de la eficiencia y productividad reduciendo el tiempo y coste invertidos en la enseñanza.
- **Durabilidad:** Resistir los cambios y evolución tecnológica sin incurrir en rediseños, reconfiguraciones o recodificaciones costosas.
- **Interoperabilidad:** Migración de componentes instruccionales desarrollados una ubicación y plataforma determinada, hacia otras distintas.
- **Reusabilidad:** Flexibilidad para incorporar componentes instruccionales en distintos contextos y aplicaciones

Estos principios resultan en la definición de las habilidades que se intentan garantizar mediante el estándar SCORM; en lo que respecta a los aspectos técnicos, SCORM se centra en 3 partes principales:

- **CAM (Content Aggregation Model):** Creación y empaquetamiento de OA.
- **RTE (Run-Time Especification):** Normas para el proceso de lanzamiento (mostrarlo en un contexto determinado) de OA.
- **SN (Sequencing and Navigation):** Responsabilidades de la plataforma con respecto al orden en los cuales se van a presentar los OA y los eventos de navegación que produzca el usuario.

1.4 Personalización y adaptación en e-Learning

La personalización tiene varios significados según el contexto en la que se emplee, en el área del *e-Learning* está centrada en el cambio de la perspectiva de la enseñanza tradicional en la cual se ve a los estudiantes como una sola unidad homogénea; en su lugar reconoce a los estudiantes como una mezcla de unidades heterogéneas. Esencialmente en el contexto de *e-Learning*, se ofrece la personalización de una variedad de elementos en el proceso de educación en línea, los elementos que más destacan son:

- Ambiente de aprendizaje
- Contenido de aprendizaje
- Interacción

En otras palabras, la personalización en *e-Learning*, busca darles la oportunidad a los estudiantes de aprender lo que ellos deseen cuando lo deseen, en inclusive aprender basado en su método de aprendizaje de preferencia.

En los últimos años ha surgido un interés especial entre los investigadores de la educación basada en computación, sobre el tema de la adaptación de la enseñanza, como resultado han surgido dos características clave adaptación y adaptabilidad (Klašnja-Milićević A. , Vesin, Ivanović, Budimac, & C. Jain, 2016), las cuales permiten a las máquinas modificar su interacción con los usuarios, entendiendo por usuario al estudiante y por máquina al sistema. La adaptación en *e-Learning* implica una mayor concentración en la máquina, a través de comportamientos en los cuales se disparan acciones para guiar en el proceso de aprendizaje,

estas decisiones se basan en las preferencias del estudiante y el objetivo que tenga el sistema, en el caso de OA las acciones se referirían a la selección de objetos específicos para el usuario. Por otro lado, se encuentra la adaptabilidad, la cual es más un comportamiento centrado en el usuario, en el cual el usuario toma decisiones y realiza cambios en el proceso de aprendizaje, es decir, pueden personalizar sus lecciones; en el caso de un objeto de aprendizaje el usuario podría ser capaz de indicar su ubicación en una interfaz.

Las características antes mencionadas son prácticamente inseparables para un aprendizaje personalizado, ya que permite un desarrollo de habilidades o criterios seleccionados con anterioridad por parte del instructor, por ejemplo, el desarrollo de habilidades basadas en contenidos, competencias, o la reducción del tiempo estimado de una clase, entre otras cosas.

1.5 Técnicas de recomendación en e-Learning

Antes de mencionar las técnicas de recomendación, es conveniente entender a los sistemas de recomendación, ya que están íntimamente ligados a dichas técnicas; si lo definimos de una manera corta se podría decir que son sistemas de información que sugieren ítems a usuarios basados en su comportamiento y/u otros tipos de datos (Ricci, Rokach, Shapira, & Kantor, 2011), es decir, son sistemas de filtrado capaces de tomar la iniciativa y presentarle al usuario distintos contenidos que se consideren útiles o interesantes sin que él realice una consulta, basándose en las preferencias del usuario y/o de una comunidad de usuarios; dichos sistemas se basan en dos tipos de recolección de información para poder predecir los contenidos que presentan a los usuarios:

- **Implícita:** La recolección de información acerca de los gustos del usuario es acumulada de manera imperceptible, a través del análisis del comportamiento que tiene el usuario; este comportamiento puede ser el historial de navegación, clics realizados, links abiertos, entre otros. Este método no requiere esfuerzo por parte del usuario, sin embargo, no es muy preciso debido a que no se puede establecer que el comportamiento que se utilice para inferir una sugerencia se base en una preferencia real del usuario.
- **Explícita:** Requiere un mayor esfuerzo por parte del usuario ya que la información que se necesita para poder generar sugerencias es obtenida a través de calificaciones(ratings) para ítems provistas por el mismo usuario, de esta

manera se generan sugerencias más precisas, sin embargo, genera molestia al usuario dado que debe proveer de información constante al sistema para sugerencias certeras.

Dentro de los sistemas de recomendación existe una gran variedad de algoritmos de recomendación que se basan en distintas técnicas y principios (Klašnja-Milićević A. , Vesin, Ivanović, Budimac, & C. Jain, 2016), básicamente todos tienen el mismo objetivo y parten desde puntos de vista similares; la diferencia radica en la manera en la que escogen y ordenan los ítems a recomendar.

Los algoritmos se basan en las calificaciones o ratings que el usuario ha generado y establece una posible afinidad entre el usuario y los ítems que éste desconoce, de esta manera se generan sugerencias en forma de ranking donde los primeros ítems tienden a ser los mejor puntuados y por ende las mejores sugerencias posibles para el usuario; según la forma de predicción de los algoritmos, éstos pueden ser agrupados en tres grupos:

- **Colaborativos:** Sistemas que intentan generar recomendaciones acertadas basándose en recomendaciones de otras personas con gustos similares (Manouselis, Drachsler, Verbert, & Duval, 2012).
- **Basados en contenidos:** Emplea descriptores iniciales tanto para usuarios como para los ítems a recomendar, de modo que emplea esa información para predicciones sobre intereses de usuarios (Burke, 2002).
- **Híbridos:** Combina las técnicas colaborativas y basadas en contenido, lo cual evita ciertas limitaciones que posean las técnicas por separado; de esta manera se genera un modelo unificado que genere recomendaciones más precisas y efectivas.

Los sistemas *e-Learning* emplean distintas técnicas de recomendación basadas en los grupos anteriormente mencionados, la diferencia es que las técnicas ponen especial atención en las preferencias y conocimiento del estudiante; además del historial de navegación de otros estudiantes con características similares, sin embargo, como antes se mencionó cada estrategia posee sus propias fortalezas y debilidades; por ende la elección del algoritmo debe basarse en las necesidades que se requieran satisfacer y hacia quién están dirigidas las recomendaciones ya que pueden centrarse en los estudiantes o docentes.

1.6 Agentes y sistemas multi agentes

El término de agente no está íntimamente ligado a la computación, por ejemplo en la filosofía se le considera a un agente a un ente que actúa con un propósito dentro de un contexto social; ahora en el contexto de la computación un agente puede definirse como un sistema computacional capaz de actuar de manera autónoma para satisfacer sus objetivos y metas, mientras se encuentra situado persistentemente en su medio ambiente (Guerra, 2013). El concepto de autonomía en un agente implica que puede realizar acciones sin intervención directa de los humanos, además de tener el control de sus acciones y su estado interno. Ahora encapsular las características de un agente es algo complicado debido a que se basan en los objetivos para los que son desarrollados, sin embargo, un agente debería cumplir con tres características básicas:

- **Sensible:** Percibir su ambiente (mundo físico, Internet, un conjunto de agentes, entre otros) y responder oportunamente a los cambios que ocurran en él.
- **Proactivo:** Las acciones no deben ser simples respuestas a cambios en su ambiente, deben basarse en las metas u objetivos para los cuales fue diseñado el agente.
- **Social:** Disponibilidad para una comunicación con otros agentes o humanos para solucionar sus propios problemas o ayudar a otros con la solución de sus problemas.

Al hablar de la propiedad “social” dentro de un agente, surge una interacción entre varios agentes, como resultado se obtienen sistemas multi agentes; dichos sistemas se reúnen y comunican para lograr cumplir con un fin en común, a través de la cooperación y coordinación de esfuerzos; los agentes por lo general poseen capacidades, conocimientos y recursos únicos o específicos, debido a esto, generar una interacción con otros agentes tiende a ser complicado o en ocasiones riesgoso, pero la delegación de tareas puede minimizar los riesgos.

En el ámbito del *e-Learning* la investigación de agentes ha tenido mucho interés en años recientes, con el fin de guiar y motivar a los estudiantes a través del proceso de aprendizaje. Con esto en mente, han surgido agentes cosechadores (recolección de material de aprendizaje desde la web) y pedagógicos (guías para los usuarios a través de aprendizaje multimedia) dentro de este dominio, de tal manera que conforman sistemas multi agentes que ayudan en el proceso aprendizaje.

1.7 Ambientes inteligentes

Los ambientes inteligentes (AmI de sus siglas del inglés *Ambient Intelligence*) son un área de investigación relativamente nueva, que tiene como fin la creación de espacios habitables donde los usuarios interactúan con servicios computacionales de una manera natural e intuitiva, de tal modo que faciliten el desempeño de sus actividades diarias; por ende estos ambientes son sensibles a las demandas del usuario y aprenden de él para poder reaccionar de manera personalizada y coherente al contexto, según (Denning, 2001) las principales características de un sistema de Inteligencia Ambiental son:

- **Discreción:** Los dispositivos deben integrarse de manera imperceptible en el entorno, tanto física como psicológicamente.
- **Personalización:** Deben reaccionar acorde al perfil de usuario y la situación.
- **Adaptabilidad:** Adaptarse acorde a los cambios del entorno y usuario.
- **Pro actividad:** Anticipar las necesidades del usuario.

1.7.1 Agentes en ambientes inteligentes e-Learning

En el ámbito de la educación los ambientes inteligentes tienen como fin ayudar de una manera transparente al proceso de aprendizaje, a este tipo de AmI se les conoce como Salones o Aulas Inteligentes; por lo general estos salones están constituidos por dispositivos electrónicos como pizarras inteligentes, sensores, actuadores, entre otros; y por software tales como sistemas de recomendación, OA, aulas virtuales, entre otros. Ahora bien la coordinación y comunicación entre componentes es algo crucial para modelar un entorno adecuado que apoye los procesos de aprendizaje de los estudiantes en un ambiente inteligente, para esto se han implementado los sistemas multi agentes, los cuales apoyan la cooperación y coordinación de los distintos componentes que conforman el entorno de aprendizaje, estos componentes son agentes centrados en las actividades de los estudiantes que monitorean sus comportamientos y se adaptan a sus necesidades, obviamente estos sistemas multi agente se basan en los principios del e-Learning para lograr su meta. Un ejemplo puede ser la arquitectura multi agente ISABEL (Information Software Agent-Based E-Learning) la cual se basa en un agente tutor y agente estudiante, los cuáles colaboran para generar recomendaciones basadas en el perfil de estudiante y de la comunidad de estudiantes

con características similares, de tal manera que pueden ofrecer contenido basado en los gustos de cada estudiante (Garruzzo, Rosaci, & Sarne, 2007).

1.8 Algoritmos de filtrado híbrido-mixto para recomendación de contenidos

La investigación *Algoritmo de filtrado Híbrido-Mixto para recomendación de Contenidos Audiovisuales a Comunidades Virtuales*, realizada en el año 2013 en la Universidad Tecnológica de Pereira, a cargo de los ingenieros Diego Duran y José Arciniega, propuso un algoritmo de recomendación híbrido para contenidos audiovisuales, enfocándose en la dinámica de las comunidades virtuales, para trabajar en función de los niveles de interés del usuario activo, con el objetivo de reducir la dispersión de datos y poder generar recomendaciones de mejor calidad, así como, reducir los efectos del Cold-Start ⁷(Arranque con información insuficiente) al momento de generar las recomendaciones. (Duran & Arciniega, 2013)

Durante su investigación se determinaron 4 consideraciones para obtener la mayor precisión en las recomendaciones: la dinámica de los usuarios (comunidad virtual de la cual se obtienen las preferencias de contenido), el entorno de la aplicación (la manera en la que el algoritmo obtiene información de preferencias del usuario), los objetivos del sistema (el enfoque que posee el algoritmo, en su caso híbrido) y el modelado de la información de los contenidos (modelar los contenidos en función de la temática y clasificación de interés para las comunidades virtuales).

A partir de esas consideraciones se llegó a determinar el modelo adecuado para el algoritmo:

⁷ Limitación que se manifiesta hasta no alcanzar un número elevado de usuarios registrados o de información relacionada con sus preferencias, por lo que no se dispone de información suficiente para extraer recomendaciones de calidad

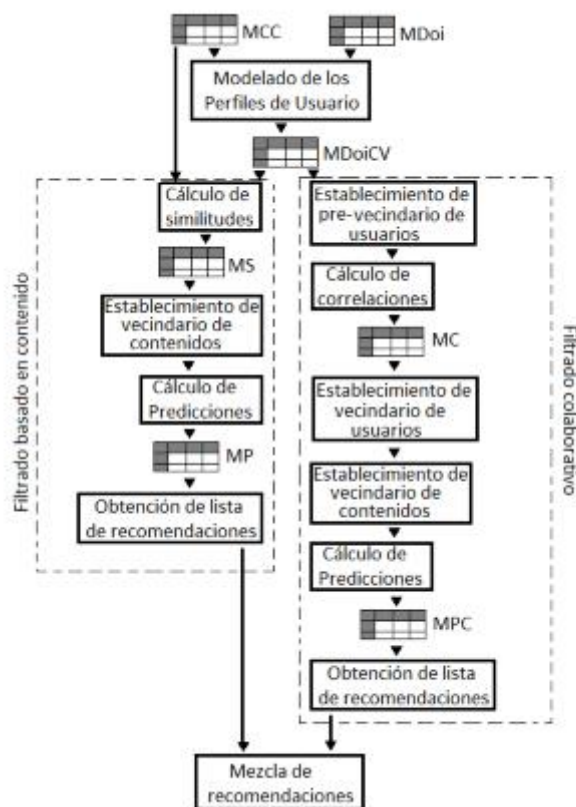


Figura 3: Algoritmo de filtrado híbrido-mixto

Fuente: (Duran & Arciniega, 2013)

Este modelo se basa en dos etapas que se ejecutan en paralelo de los filtros colaborativo y basado en contenido de tal manera, que la recomendación final es la combinación de cada uno de los filtros. En principio el algoritmo basado en contenido se rige por los cálculos de similitud de coseno, a través del cual se genera una matriz de similitudes con valores entre 1 o 0, y finalmente realizar un cálculo de predicciones para cada usuario activo por cada contenido que hace parte de su vecindario. Por otra parte, el filtrado colaborativo se fundamenta en el cálculo de las correlaciones de Pearson basándose en los perfiles de los usuarios activos y sus vecinos para posteriormente formar una matriz de correlaciones.

Este modelo finalmente se implementó a través de componentes Java para cumplir con los pasos de los filtros y las matrices se establecen en tablas relacionales MySQL, con un ambiente de prueba con doce comunidades académicas virtuales, once usuarios miembros de cuatro comunidades en promedio, doce contenidos asociados a tres comunidades en promedio y un promedio de nueve matrices de interés por usuario. A partir de las

recomendaciones proporcionadas se realiza una prueba de precisión, por medio del MAE (error medio absoluto), obteniendo los siguientes resultados:

Cantidad de vecinos	MAE Algoritmo propuesto	Porcentaje de aciertos	MAE Algoritmo tradicional
1	0,7	57%	0,87
2	0,68	57%	0,87
3	0,67	57%	0,87
4	0,65	57%	0,86
5	0,63	57%	0,86

Figura 4: Tabla comparativa de valores de MAE y porcentaje de aciertos del filtrado colaborativo entre el algoritmo propuesto y el tradicional

Fuente: (Duran & Arciniega, 2013)

A partir de estos resultados, es posible: el cálculo anticipado de vecinos que permitan la reducción del error en las predicciones; además, la reducción de los efectos del problema Cold-Start, de tal manera que se obtienen recomendaciones aun con una baja cantidad de niveles de interés registrados en el sistema, por consiguiente, se reduce la carga computacional del proceso de filtrado.

1.8.1 Similitud de coseno

En la investigación de “*Algoritmo de filtrado Híbrido-Mixto para recomendación de Contenidos Audiovisuales a Comunidades Virtuales*”, mencionada en el punto anterior, se indica el uso del algoritmo de similitud de coseno para el filtro basado en contenido, sin embargo, en el caso de trabajar con similitudes entre usuarios, tradicionalmente el algoritmo se emplea en filtros colaborativos, debido a que permite calcular la similitud de perfil comparando vectores de clasificación entre el usuario objetivo y otros usuarios, comparando las opiniones de los usuarios con respecto a los artículos o ítems, otras métricas de distancia empleadas son la fórmula de Pearson o Spearman (Balabanović & Shoham, 1997). Si por el contrario se trabaja con similitudes entre elementos las medidas son solo las de Pearson y la de coseno.

El algoritmo de similitud de coseno no es el único en su tipo, pero a pesar de su uso, no se ha justificado su efectividad; en el estudio *A Latent Source Model for Online Collaborative Filtering* realizado por Guy Bresler, George H. Chen y Devavrat Shah esta efectividad es puesta a prueba en un entorno en línea. La visión clave de su trabajo son dos tipos de

exploración en el algoritmo: la exploración aleatoria estándar para explorar el espacio de los ítems, y una nueva exploración "conjunta" para encontrar diferentes tipos de usuarios. Estas exploraciones se realizan a través de la adaptación del algoritmo a sus necesidades, es decir, que mantienen el principio del algoritmo, pero realizan pequeños cambios para comprobar el éxito de los resultados obtenidos, a esta modificación la llamaron COLLABORATIVE-GREEDY (Bresler, Chen, & Shah, 2014).

Los resultados que obtuvieron, se basaron en un escenario de prueba de un sistema de recomendación en línea utilizando un conjunto de datos de clasificaciones de películas de Movielens10m y Netflix; utilizando esta información se compararon los resultados obtenidos con los algoritmos Popularity Amongst Friends (PAF) y el método Deshpande and Montanari(DM) para verificar cuán efectivo es el algoritmo. Al final el algoritmo de similitud de coseno obtuvo un 80.7% de predicciones distintas a cero y para Netflix un 86.0%, en la Figura 5 se puede observar el comportamiento de cada algoritmo, siendo la recompensa la recomendación obtenido con respecto al tiempo.

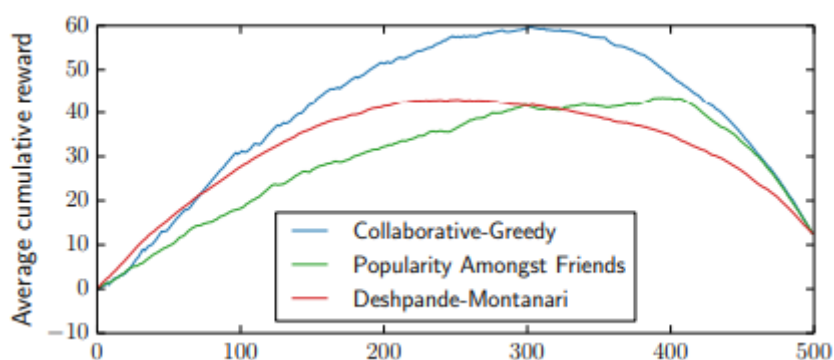


Figura 5: Promedio de recompensas acumuladas a lo largo del tiempo

Fuente: (Bresler, Chen, & Shah, 2014)

Básicamente los resultados del estudio justifican de manera teórica, cuando un método de filtrado colaborativo de similitud de coseno funciona bien, otro trabajo similar es el de Gerard Biau, Benoît Cadre, y Laurent Rouvière quienes estudian la consistencia asintótica de un método de filtro colaborativo de vecindad similar entre vecinos con el objetivo de predecir la clasificación del siguiente elemento oculto (Biau, Cadre, & Rouvière, 2010).

CAPÍTULO II

MATERIALES Y MÉTODOS

2.1 Marco metodológico

Este trabajo consiste en dos tipos de investigación, primero la investigación documental, ya que, a través de la recopilación y análisis de distintas fuentes bibliográficas, se puede sustentar las técnicas y algoritmos que se utilizarán en el desarrollo del modelo de agente propuesto; así como también la investigación aplicada, puesto que a partir del conocimiento adquirido se construye un prototipo funcional, desarrollado a través de la metodología ágil XP; posteriormente el prototipo puede orientarse a la producción de conocimiento.

La revisión de documentos es la principal fuente de información para el desarrollo del proyecto, sin embargo, con el fin de validar sus funciones en un ambiente de pruebas, se requiere de la recreación de perfiles de estilos de aprendizaje de los estudiantes, llevándose a cabo al implementar un cuestionario basado en ILS (Index of Learning Styles) de Felder y Silverman a un grupo de personas; y la simulación de recursos (OA) para asignaturas predefinidas que se encuentren en un repositorio digital.

Al establecer el ambiente de pruebas, se puede validar el comportamiento del agente con respecto a las recomendaciones que ofrezca basándose en los distintos perfiles de estudiantes, de esta manera se puede optar por un enfoque cualitativo que permita determinar si cumple con los siguientes atributos de calidad de software: funcionalidad, escalabilidad y mantenibilidad.

2.2 Análisis del contexto de asignación de recursos en la PUCE-SI

Como parte del proceso de elaboración de la planificación académica o “Syllabus”, el docente debe elegir cuáles son los recursos didácticos y/o actividades que empleará para cada contenido que va a impartir, siendo los recursos herramientas o materiales de apoyo para la construcción del conocimiento de los estudiantes. Sin embargo, la elección no es definitiva hasta el momento de impartir la clase, es decir, el docente indica los tipos de recursos a emplear, tales como: libros, videos, presentaciones, entre otros; pero no especifica el contenido de los mismos (título del recurso o ubicación electrónica). Esta especificación se realiza al momento de impartir la clase, en la cual el docente analiza los recursos que

mejor se adapten al contenido de la clase y al contexto de sus alumnos; este proceso se especifica en el diagrama de actividades presentado en la Figura 6.

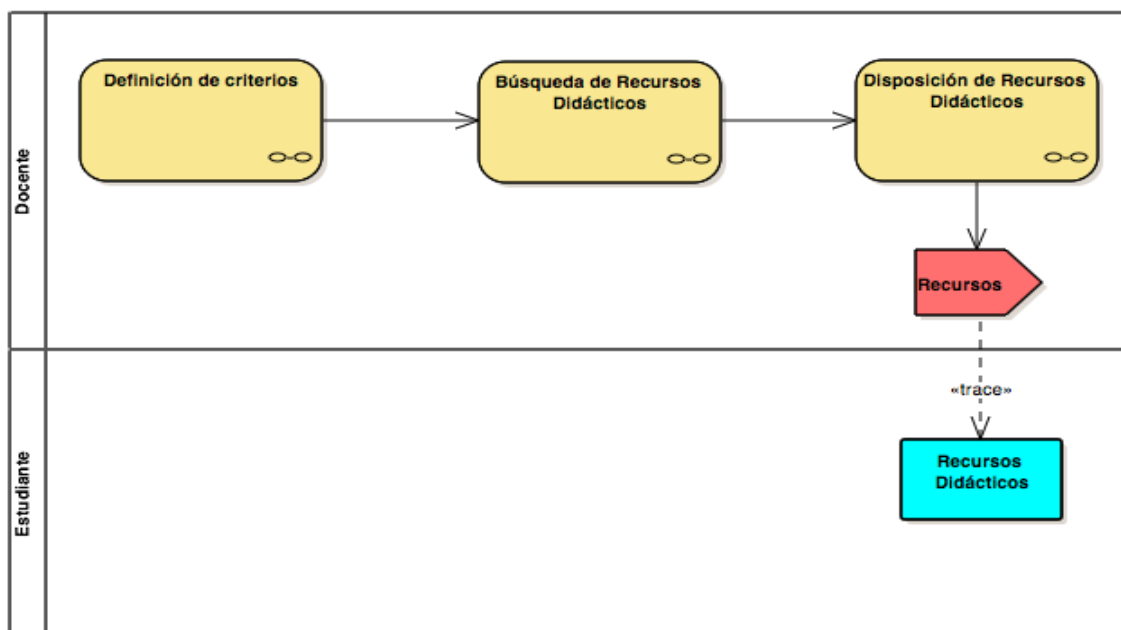


Figura 6: Elección de recursos didácticos para una clase

Fuente: Bryan Arellano

Cuando se habla del contexto de los alumnos, se hace referencia a la definición de criterios o identificación de las capacidades y conocimientos actuales de los estudiantes en conjunto con los objetivos y resultados que se desean obtener al final de la clase, tal como se presenta en el diagrama de actividades de la Figura 7, de esta manera se obtiene como resultado el recurso adecuado para el contexto de la clase.

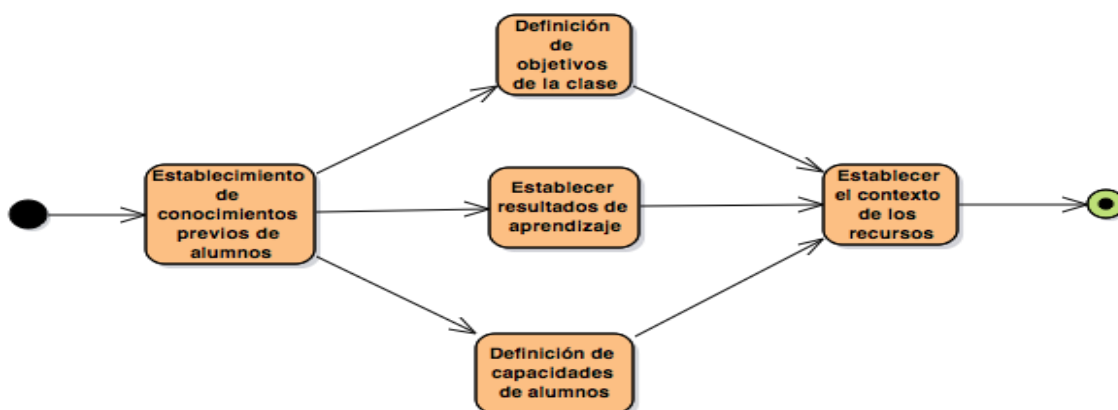


Figura 7: Definición de criterios para elección de recursos didácticos

Fuente: Bryan Arellano

Al conocer los recursos que deben usarse para alcanzar los objetivos de aprendizaje de cada tema, el docente inicia la búsqueda de los mismos con el fin de encontrar aquellos que posean las características necesarias para cumplir con las metas de la clase, dependiendo de los medios que estén a su alcance, el docente realiza una búsqueda física en la biblioteca o una búsqueda digital (Figura 8). Una vez identificados los recursos que empleará, procede a distribuirlos a los estudiantes; dependiendo de las características de los recursos, éstos pueden distribuirse por medios electrónicos como un aula virtual o por medios convencionales como una distribución física en un aula de clases, esto se muestra en la Figura 9.

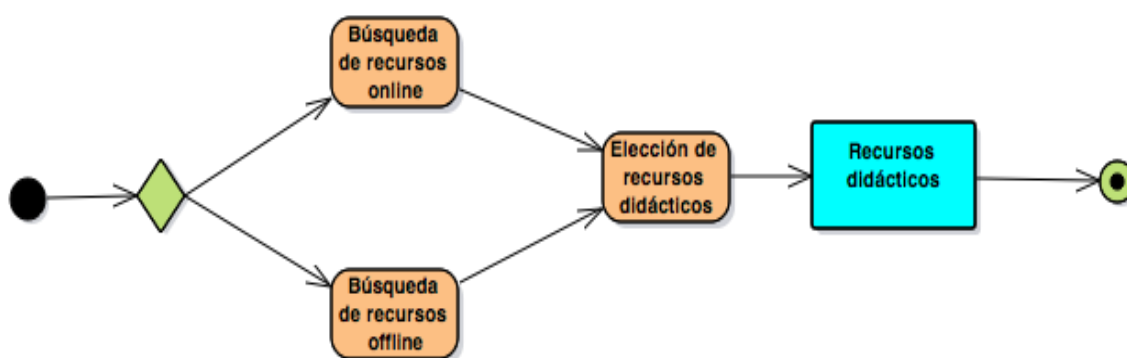


Figura 8: Búsqueda de recursos

Fuente: Bryan Arellano

La diferencia principal radica en la definición de los criterios para las actividades, ya que básicamente el docente debe decidir qué tipo de actividad se ajusta a los objetivos de su clase y cuál es el recurso adecuado para apoyar dicha actividad, basándose en los contenidos de información y el uso que se espera hacer de ellos (Figura 11). Estas actividades se pueden clasificar en tres grupos (Penzo, 2009):

- **Actividades de memorización:** Reproducen los contenidos de información, de la forma más literal y exacta posible.
- **Actividades de aplicación:** La información que hay que utilizar es especificada, pero el proceso consiste en el uso de la información a casos o ejemplos concretos.
- **Actividades de problemas:** Básicamente el estudiante debe tomar las decisiones sobre qué información debe emplear para resolver un problema.

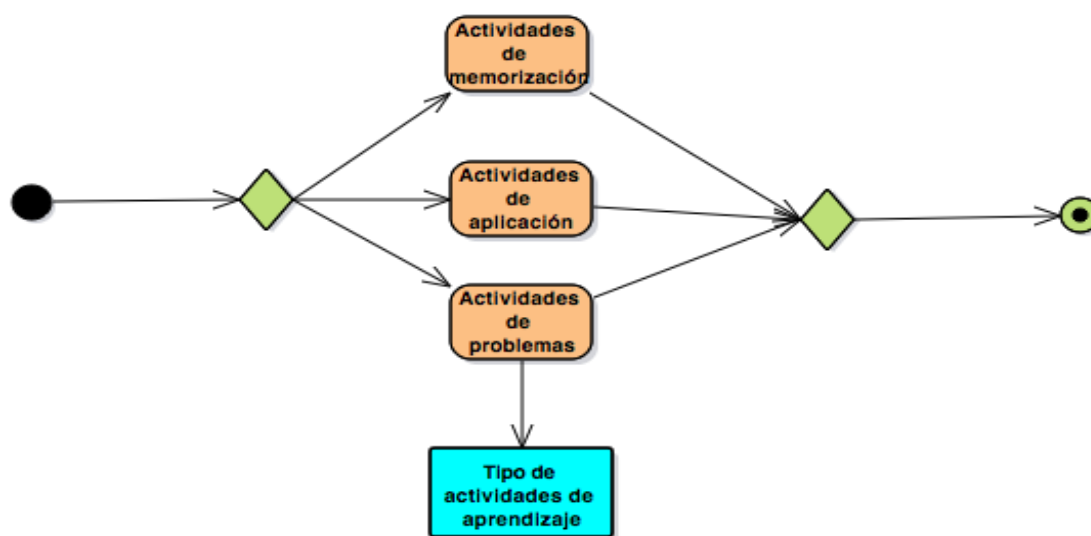


Figura 11: Definición de contexto de actividades de aprendizaje

Fuente: Bryan Arellano

Al tener identificado el tipo de actividad idónea para el refuerzo del aprendizaje, el flujo de las actividades que realiza el docente para buscar y distribuir los recursos no cambia, véase la Figura 6 y Figura 10, el recurso como resultado de estos criterios es el único que está sujeto a cambios, es decir, dependiendo del objetivo o criterios que se tengan en mente un recurso como resultado podría ser un libro, problemas a resolver, videos, ejercicios propuestos, entre otros.

2.3 Especificación del test para la identificación de estilos de aprendizaje

Para la formulación de un cuestionario que sea capaz de determinar el perfil de aprendizaje de un estudiante se tomó en consideración la clasificación de Felder y Silverman (1988), ya que diseñaron un test válido para descubrir las preferencias de aprendizaje de una persona, de tal manera que cada individuo que lo realizase, pudiera calcular los resultados por su cuenta. Este test es conocido como Index of Learning Styles o ILS, presentando un total de 44 preguntas con dos opciones cada una; incluyendo en la parte final instrucciones para cuantificar las respuestas y determinar las tendencias del individuo, estas tendencias no se reflejan con un solo estilo predominante, por el contrario los resultados muestra un valor correspondiente a cada segmentación de estilo (Figura 13). Las preguntas se distribuyen de la siguiente manera:

Escala	Items
• Sensorial-Intuitivo	• 38, 6, 18, 14, 2, 10, 34, 26, 22, 42, 30
• Visual-Verbal	• 7, 31, 23, 11, 15, 27, 19, 3, 35, 43, 39
• Global-Secuencial	• 20, 36, 44, 8, 12, 32, 24, 28, 4, 16, 40
• Activo-Reflexivo	• 25, 1, 29, 5, 17, 37, 13, 9, 21, 33, 41

Figura 12: Resumen de agrupaciones de items en ILS

Adaptado por: Bryan Arellano

Fuente: (Litzinger, Lee, Wise, & Felder, 2007)

Questionnaire Results for :

➤ Reflective: 1 ➤ Sensing: 3 ➤ Verbal: 5 ➤ Global: 3




Figura 13: Resultados de ILS

Fuente: (NC State University, 2017)

Ahora bien, un docente al momento de escoger recursos didácticos, puede elegir libros, videos, ejercicios, entre otros; ahora que pasaría si a cada uno de estos recursos se agrupan de la siguiente manera:

- **Visuales:** Correspondiendo a imágenes, diagramas, esquemas, entre otros.
- **Verbales:** Audio, texto y video de cualquier tipo; y
- **Activos:** Ejercicios, problemas, entre otros.

Las agrupaciones establecidas en teoría corresponden a un estilo de aprendizaje en particular; como se puede observar existen cuatro segmentos de estilos de aprendizaje, de los cuales dos son los que encajan con los grupos de recursos establecidos: visual-verbal y activo-reflexivo, a partir de éstos podemos eliminar sus segmentaciones y establecerlos individualmente: visual, verbal y activo; la elección de estos estilos en particular, se debe a que sus comportamientos son los más cercanos a un modelo de refuerzo de conocimiento a través de recursos, refiriéndose a que pueden ser empatados con objetos físicos y de una manera casi inmediata, mientras que el resto de estilos se orientan más hacia un comportamiento al momento de asimilar información, ya sea a corto o largo plazo.

Como resultado del proceso de separación de segmentos de estilos de aprendizaje, se obtienen grupos de trabajo en los que un agente inteligente puede enfocarse y distribuir recursos adecuadamente para cada estudiante. Pero aún establecidos dichos grupos de trabajo se requiere de un test que permita cuantificar el estilo que posee cada individuo, la manera más rápida consiste en tomar las preguntas de ILS (Figura 12) y enfocarse en las que corresponden a los estilos de aprendizaje que sean de interés, en este caso en particular, se requieren de los segmentos de visual-verbal y activo-reflexivo.

Escala	Items
<ul style="list-style-type: none"> • Visual-Verbal • Activo-Reflexivo 	<ul style="list-style-type: none"> • 7, 31, 23, 11, 15, 27, 19, 3, 35, 43, 39 • 25, 1, 29, 5, 17, 37, 13, 9, 21, 33, 41

Figura 14: Conjunto de preguntas de estilos de aprendizaje de interés

Fuente: Bryan Arellano

Como resultado se obtiene un conjunto de 22 preguntas, de las cuales se sabe lo siguiente cada respuesta consiste en dos opciones posible *a* y *b*, que se distribuyen de la siguiente manera para el conjunto de preguntas del segmento visual-verbal la opción *a* le corresponden al estilo visual por ende las opciones *b* corresponden al estilo verbal; de igual manera el conjunto de preguntas del segmento activo-reflexivo consisten en la misma distribución las repuestas a para activo y b para reflexivo. Ahora bien, el siguiente paso consiste en emparejar las preguntas que tengan cierto grado de similitud en su contexto, de esta manera obtenemos un solo grupo de preguntas que contienen respuestas correspondientes al contexto de las mismas; como se puede observar en la Figura 15, se obtienen un total de 7 conjuntos de preguntas.

Escala	Items
<ul style="list-style-type: none"> • Visual-Verbal • Activo-Reflexivo 	<ul style="list-style-type: none"> • 7, 31, 23, 11, 15, 27, 19, 3, 35, 43, 39 • 25, 1, 29, 5, 17, 37, 13, 9, 21, 33, 41

Figura 15: Emparejamiento de preguntas

Fuente: Bryan Arellano

Al tener establecidos los conjuntos de preguntas se eliminan las respuestas correspondientes al estilo reflexivo debido a que no se encuentra entre los estilos de aprendizaje de interés,

por consiguiente, se descartan las respuestas *b* del segmento activo-reflexivo. Ahora quedan establecidos 7 grupos de preguntas con tres posibles respuestas, y una pregunta con dos respuestas, esta pregunta corresponde a la número veinte y siete del segmento visual-verbal, esto se debe a que la pregunta como tal contiene respuestas que pueden encajarse con una tercera que no se encuentre entre las respuestas que ofrezcan el resto de preguntas, es decir, se puede adaptar la tercera respuesta a una que pueda corresponder al estilo activo, por otro lado el resto de preguntas que no fueron emparejadas no tienen manera alguna de empatarse o adaptarse sin cambiar su contexto o respuestas de una manera sutil. Como resultado obtenemos un conjunto de preguntas basadas en un test oficial, que se adaptan al objetivo del agente, el cual es usar un perfil de estilos de aprendizaje para poder distribuir recursos; sin embargo, la manera en que se cuantifican los resultados cambia, en este caso utilizando una regla de tres, de tal modo que se obtengan una escala distribuida entre cada estilo, por ejemplo, un individuo podría obtener un resultado de 20% visual, 50% verbal y 30% activo, para su perfil.

2.4 Análisis del agente recomendador en ambientes inteligentes de enseñanza

Un Ambiente Inteligente (AI) está conformado por un conjunto de componentes o, como es el caso de este trabajo, por un conjunto de agentes (sistema multi agentes) interactuando entre sí. Además, requiere de distintos tipos de datos y/o información, los cuales son usados en los procesos de gestión del ambiente. Esta interacción necesita un medio de comunicación o middleware, es decir, un enlace que permita a los agentes tener una forma de comunicación entre ellos y así compartir información.

Ahora bien, el agente de recomendación persigue, como objetivo, la disposición de recursos didácticos u OA personalizados, de tal manera que se seleccionen y presenten basados en los estilos de aprendizaje, ofreciendo al estudiante un refuerzo en el proceso de aprendizaje y asimilación de conocimiento. Los procesos asociados al agente recomendado se muestran en el diagrama de procesos de la Figura 16.

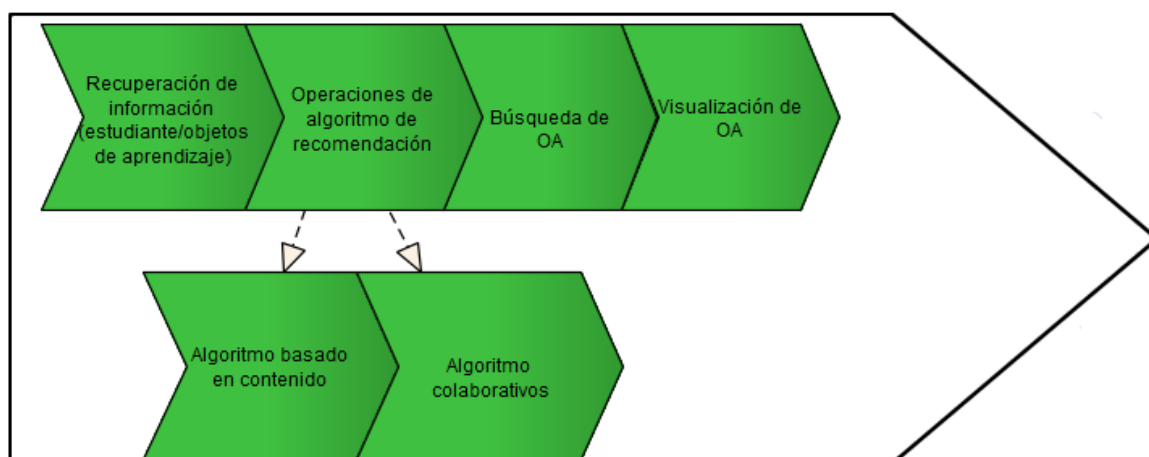


Figura 16: Cadena de valor del agente recomendador

Fuente: Bryan Arellano

Los procesos tal como se ven en la Figura 16, se comunican, es decir, que el proceso de ejecución del algoritmo de aprendizaje requiere de la información obtenidas al recuperar los OA. Por ello el proceso de comunicación es un factor importante en este trabajo.

2.5 Casos de uso del agente

A partir del diagrama de procesos, se especifica el funcionamiento del agente, el cual quedó detallado en el diagrama de casos de uso de la Figura 17, de la siguiente manera: Se supone la existencia de un agente de gestión de contenido (herramienta con la cual el docente administra el contenido de su clase) la cual interactúa con el agente recomendador (a través de algún medio de comunicación) para proveer de información consistente al contenido y OA que requiera el agente recomendador. Por otra parte, el agente recomendador necesita de la información relacionada a los estilos de aprendizaje de cada estudiante o su perfil (en caso de no existir, una calibración de estilo de aprendizaje es provista por el agente). Con esta información, el agente recomendador genera las matrices con las que pueda distinguir de mejor manera los datos que necesita para poder filtrar (encontrar) los OA más idóneos, estos filtros se aplican de manera secuencial de tal manera que al final se pueda recuperar y mostrar una lista con OA que se ajusten al perfil del estudiante. Finalmente, se debe contar con la posibilidad de que cada objeto pueda ser valorado tras su uso

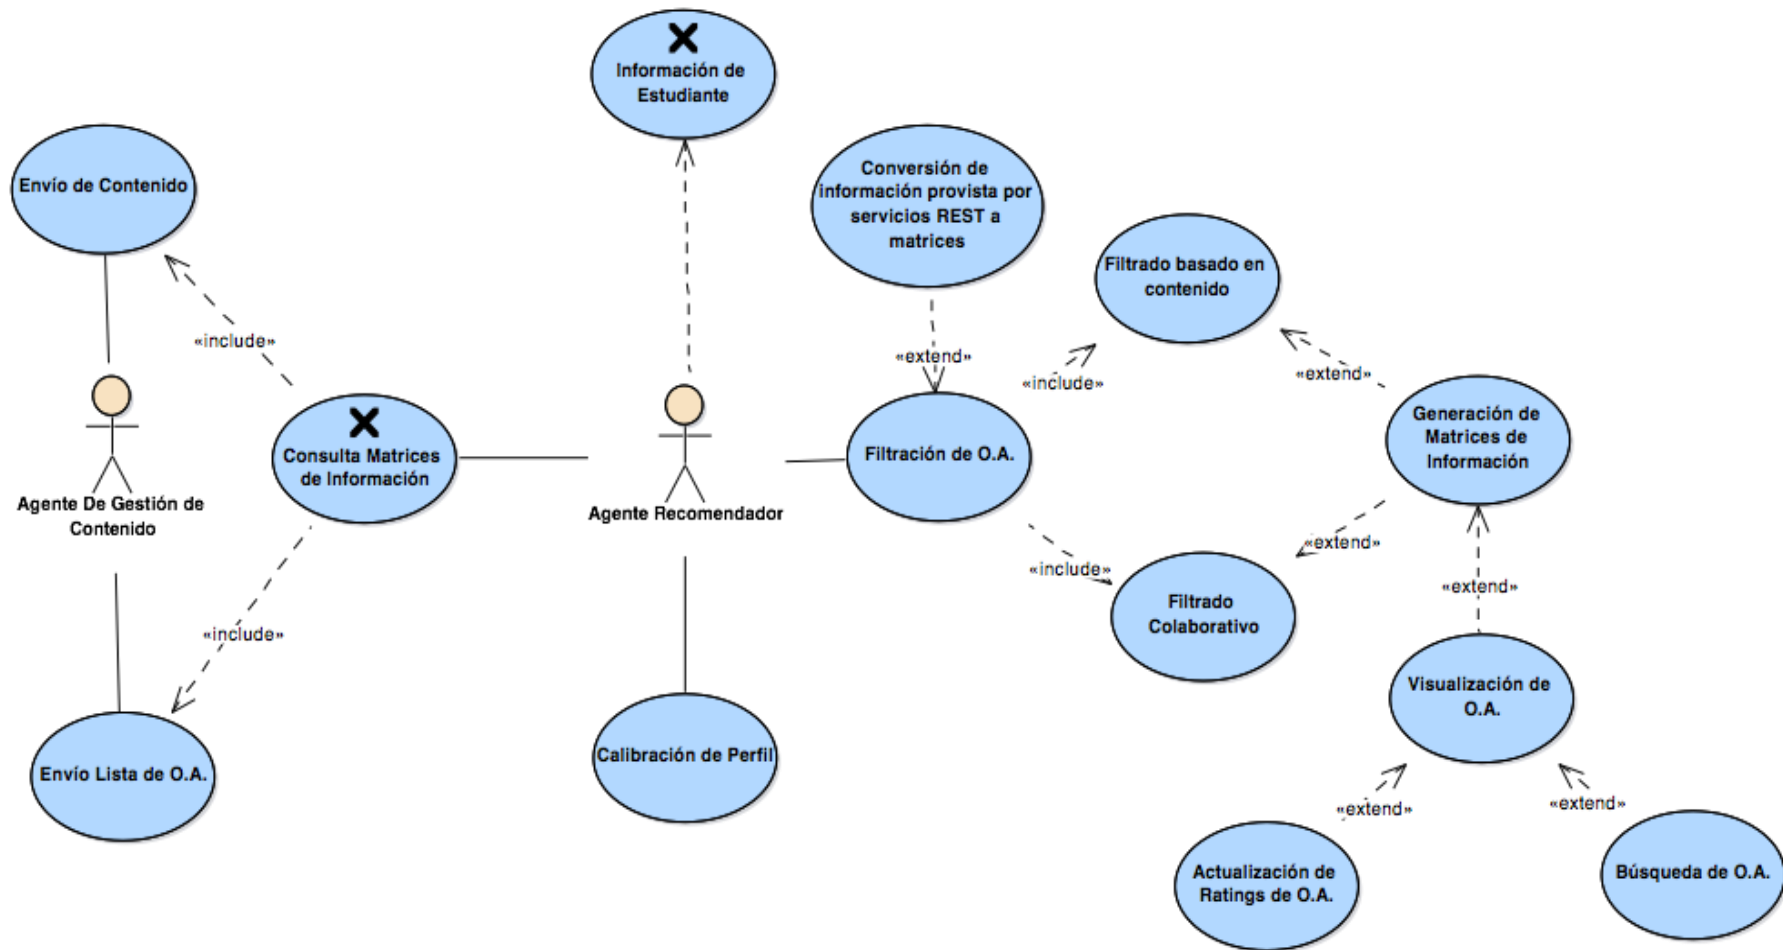


Figura 17: Casos de uso de agente recomendador

Fuente: Bryan Arellano

Si se analiza el comportamiento del agente recomendador de una manera más detallada se puede distinguir cuatro actividades fundamentales tal como se presentan en el diagrama de actividades de la Figura 18:

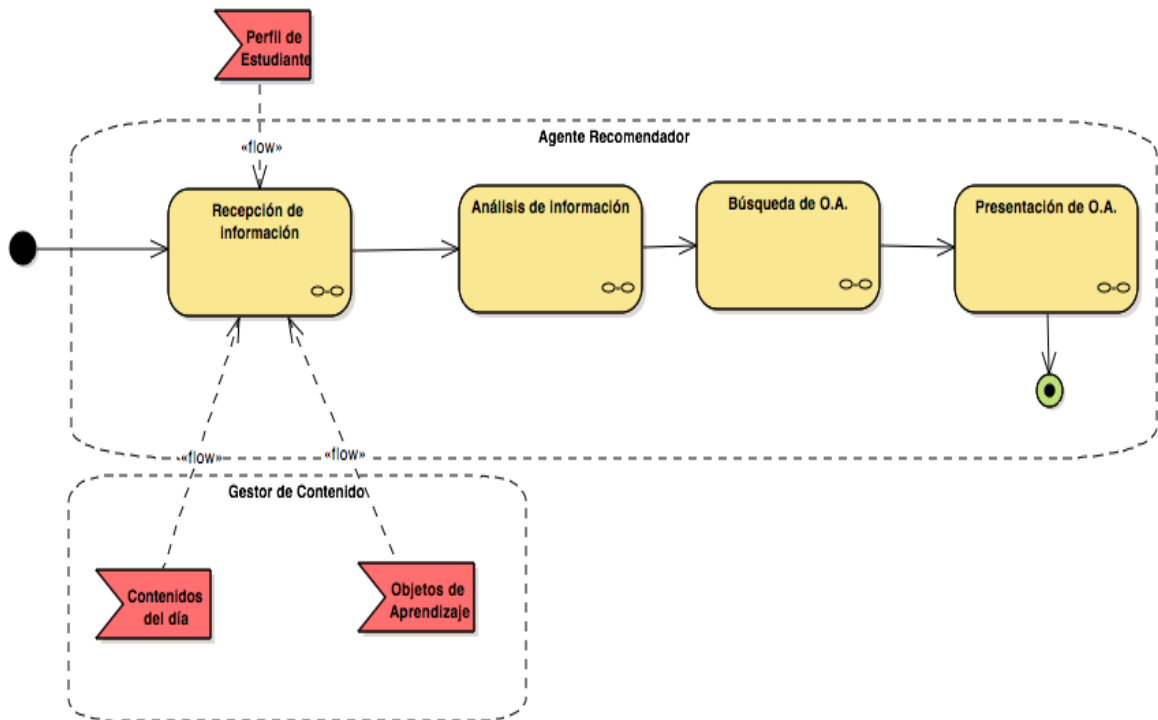


Figura 18: Diagrama de actividades de agente recomendador

Fuente: Bryan Arellano

Cada una se compone de tareas que se llevan a cabo por separado para su posterior uso en la siguiente etapa:

1. La recepción de información, consiste en la generación de matrices con los datos necesarios para los algoritmos de clasificación, estas matrices se generan a partir de la información recibida por tres fuentes (por algún medio de comunicación): perfil académico, OA correspondientes al contenido del día y valoraciones correspondientes a cada objeto. El objetivo es reorganizar cada fuente de información, de tal manera, que se obtenga una matriz con una estructura más accesible para el agente, la Figura 19.

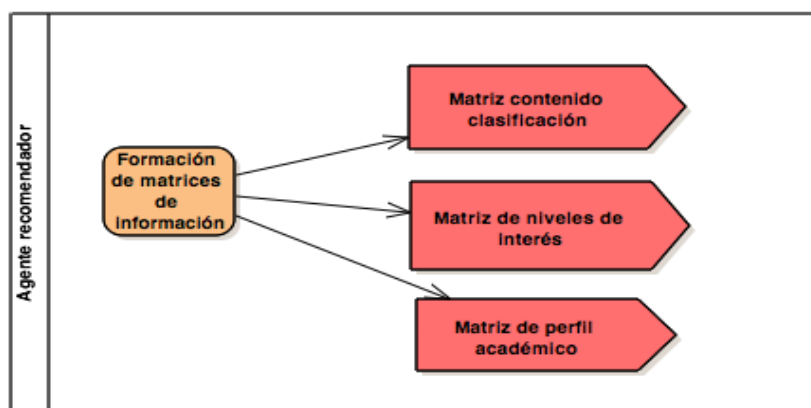


Figura 19: Tarea de composición de matrices

Fuente: Bryan Arellano

- El análisis de información implica la aplicación de los filtros de recomendación basados en contenido y colaborativos, empleando las matrices generadas en la etapa 1, a partir de la información provista por la matriz del perfil de estudiante y la de valoraciones de OA, se pueden discernir los OA que corresponden al tipo de aprendizaje del alumno en cuestión; las tareas se ejecutan de manera secuencial de modo que la aplicación de un filtro posterior al inicial mejora la recomendación de anterior basándose en sus respectivos criterios, de esta manera se obtiene una lista con los OA que mejor se aproximen a la preferencia del estudiante. La Figura 20 muestra el diagrama de actividades de este proceso.

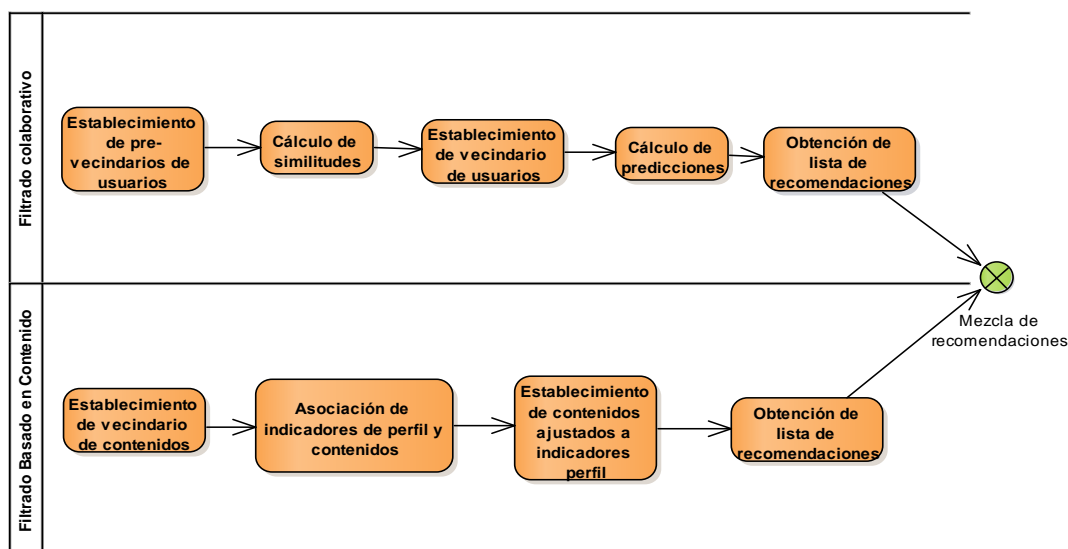


Figura 20: Aplicación de filtros de recomendación

Fuente: Bryan Arellano

3. A partir de la aplicación de filtros se inicia una búsqueda de OA, es decir, se genera una lista con los OA que los filtros consideran óptimos para el estudiante; este listado se genera a partir de la matriz que contiene los datos de cada OA para el contenido del día y el listado que se obtiene como resultado de la aplicación del filtrado, visto de otra manera se pasa a realizar una comparación en la que se desechan los objetos que no se consideran útiles, tal como se presenta en la Figura 21.

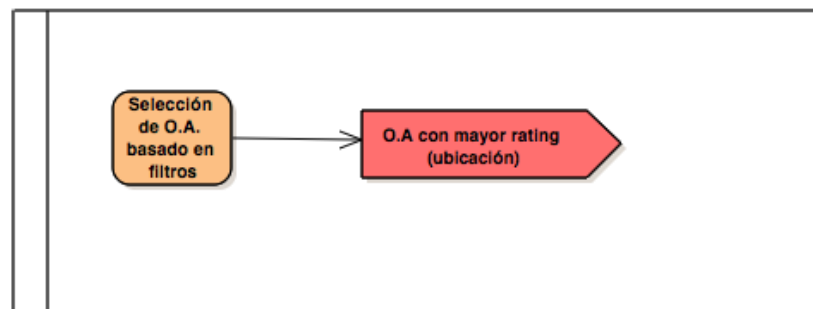


Figura 21: Filtrado de OA

Fuente: Bryan Arellano

4. En la última etapa se presentan los OA al estudiante en la plataforma en la que éste se desempeña, con la posibilidad de que valore cada OA que llegue a emplear (ver diagrama de la Figura 22).

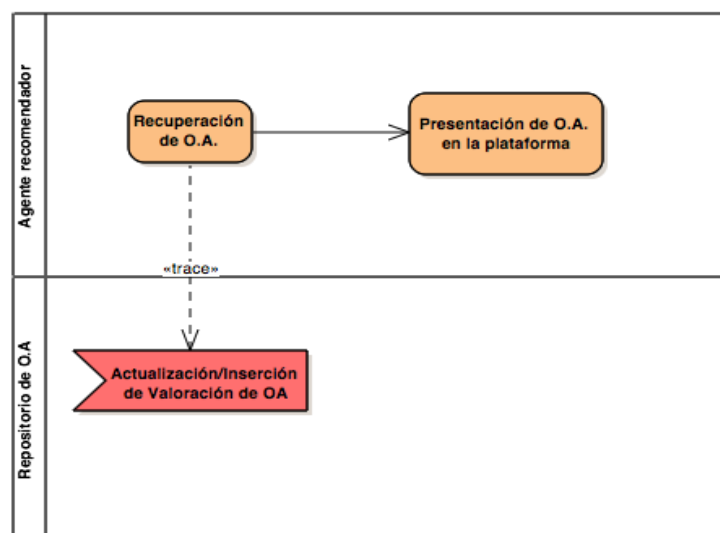


Figura 22: Presentación de OA

Fuente: Bryan Arellano

2.6 Metodología del diseño

El proyecto, tal como se estableció en el objetivo general, propone el desarrollo del prototipo del agente recomendador, para ello se decidió usar como metodología de desarrollo de software un proceso iterativo incremental. Así mismo, con el fin de realizar pruebas que permitan validar su funcionamiento y observar los resultados que arrojará el agente, se seleccionarán a prioridad un conjunto de asignaturas dictadas en la Escuela de Ingeniería de sistemas.

El diseño del sistema debe satisfacer un conjunto de atributos de calidad, tales con la funcionalidad, escalabilidad y mantenibilidad, esto con fin de construir un prototipo que pueda ser utilizado en futuros desarrollo del proyecto de investigación al cual este trabajo pertenece.

Para cumplir con los requisitos establecidos, se determinó que el proceso a llevar a cabo para el diseño del agente es un método basado en prototipos, éste método tiene como característica importante un desarrollo incremental, donde un incremento de la solución es presentado a los clientes con el fin de comprobar su funcionalidad. Además, el desarrollo incremental tiene ventaja de analizar los resultados obtenidos en el incremento, a fin de analizar sus resultados y hacer reingeniería, así como facilitar el anexar nuevas especificaciones durante el desarrollo del agente. Este tipo de metodología es útil en escenarios en los que no se tienen claros los requisitos del proyecto, que es el caso del presente trabajo (Pfleeger & Atlee, 2010).

El diseño final del agente podrá ser empleado en cualquier asignatura, pero, como ya se dijo, su funcionamiento se validará con dos asignaturas: Introducción a la Computación y Matemáticas I (tomado de los Syllabus de la PUCE-SI del período septiembre 2017-enero 2018).

Para efectos del documento el diseño de cada componente se hará a través de los diagramas de clases y/o componentes que ofrece UML para este efecto (Referencia de UML). Así mismo, dentro del diseño se harán las descripciones de las consideraciones, herramientas y/o tecnologías utilizadas para la construcción del agente.

2.7 Diseño del agente recomendador

Existen distintas maneras de crear un enlace de comunicación entre componentes o agentes, una manera sencilla, por así decirlo, es a través de servicios REST. La arquitectura orientada a servicios permite crear aplicaciones distribuidas, donde cada servicio realiza una actividad y genera información que es consumida por otro componente o servicio. En este trabajo, cada agente realiza una tarea y, en caso de ser necesario, genera información. El servicio es utilizado como un medio que permite almacenar y compartir su información para ser utilizada posteriormente.

Los servicios deben ajustarse a los objetivos del agente, así como a la información que requiere para cumplir con los mismos, la comunicación entre agentes desarrollados bajo un estilo arquitectónico orientada a servicios permite que cada agente se desempeñe de manera independiente, ya que el servicio busca y localiza información que se requiera sin tomar en cuenta de cuál es el componente que genera o presta el servicio. Inicialmente, para efectos de las pruebas de integración y funcionamiento, se estableció que la comunicación o interacción del agente recomendador con otros agentes de la arquitectura general del sistema multi agentes, descritos en la arquitectura realizada por Rivero et al. (2016), sería a lo sumo simulada. Es por ello que, la arquitectura de software a desarrollar, se hace a un alto nivel de abstracción, la misma está compuesta por un agente recomendador y un proveedor de servicio REST (para la búsqueda de OA e información del estudiante solicitado), con una comunicación abierta para cualquier agente a través de dichos servicios, la figura 23 el diagrama de componentes de la arquitectura del sistema a desarrollar, cada componente está compuesto por un conjunto de clases las cuales poseen un grupo de métodos necesarios para alcanzar los comportamientos requeridos por la interfaz del componente.

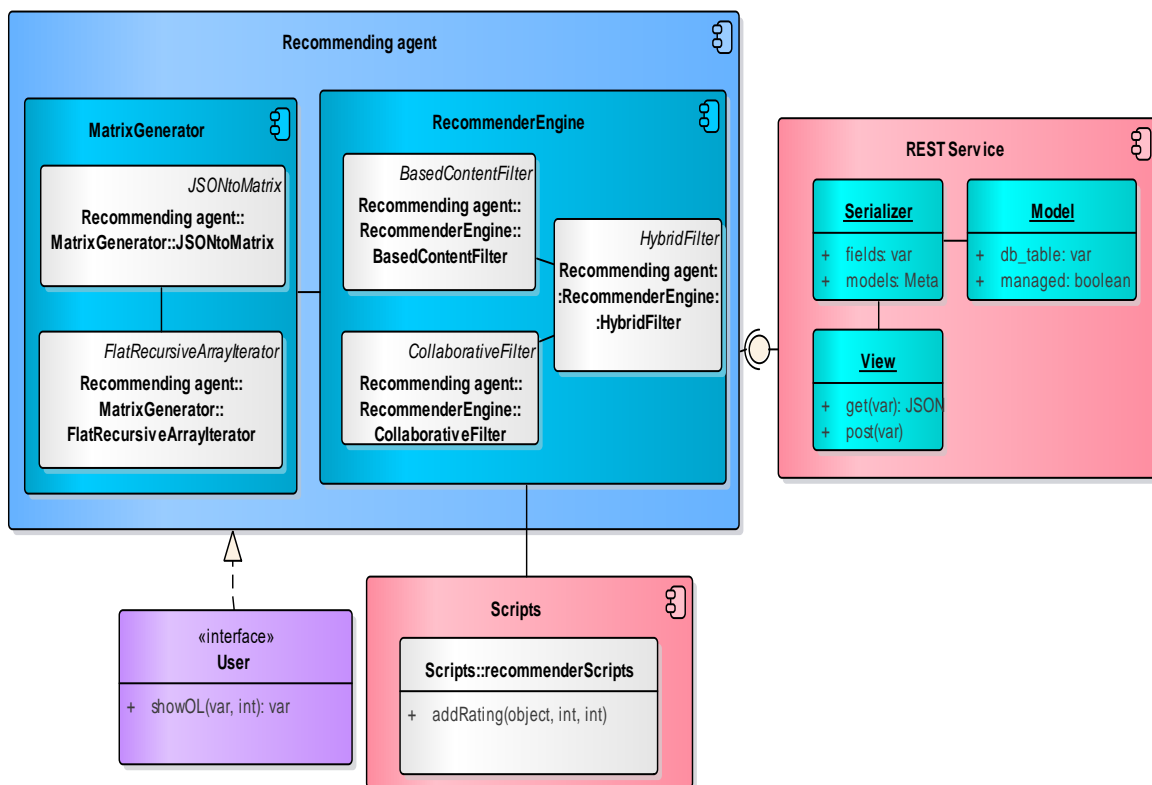


Figura 23: Diagrama de componentes de modelo de agente recomendador

Fuente: Bryan Arellano

2.7.1 Servicios REST (Representational State Transfer)

El agente recomendador requiere de información del material didáctico disponible, conocido como los OA, para seleccionar aquellos que sean más adecuados al perfil de cada usuario y así generar las sugerencias de los OA más indicados. Estos datos externos son: los datos de los perfiles de estudiantes (estilos de aprendizaje) y los datos de los OA; los cuales contienen los atributos necesarios para realizar los cálculos (ratings) de las diferentes técnicas de recomendación.

Para proveer la información antes descrita, se diseñaron servicios REST que puedan proveerla al agente recomendador. Para la comunicación de datos se utilizó un formato de información JSON (JavaScript Object Notation), los datos utilizados se plasman en el modelo de datos de la Figura 24, donde:

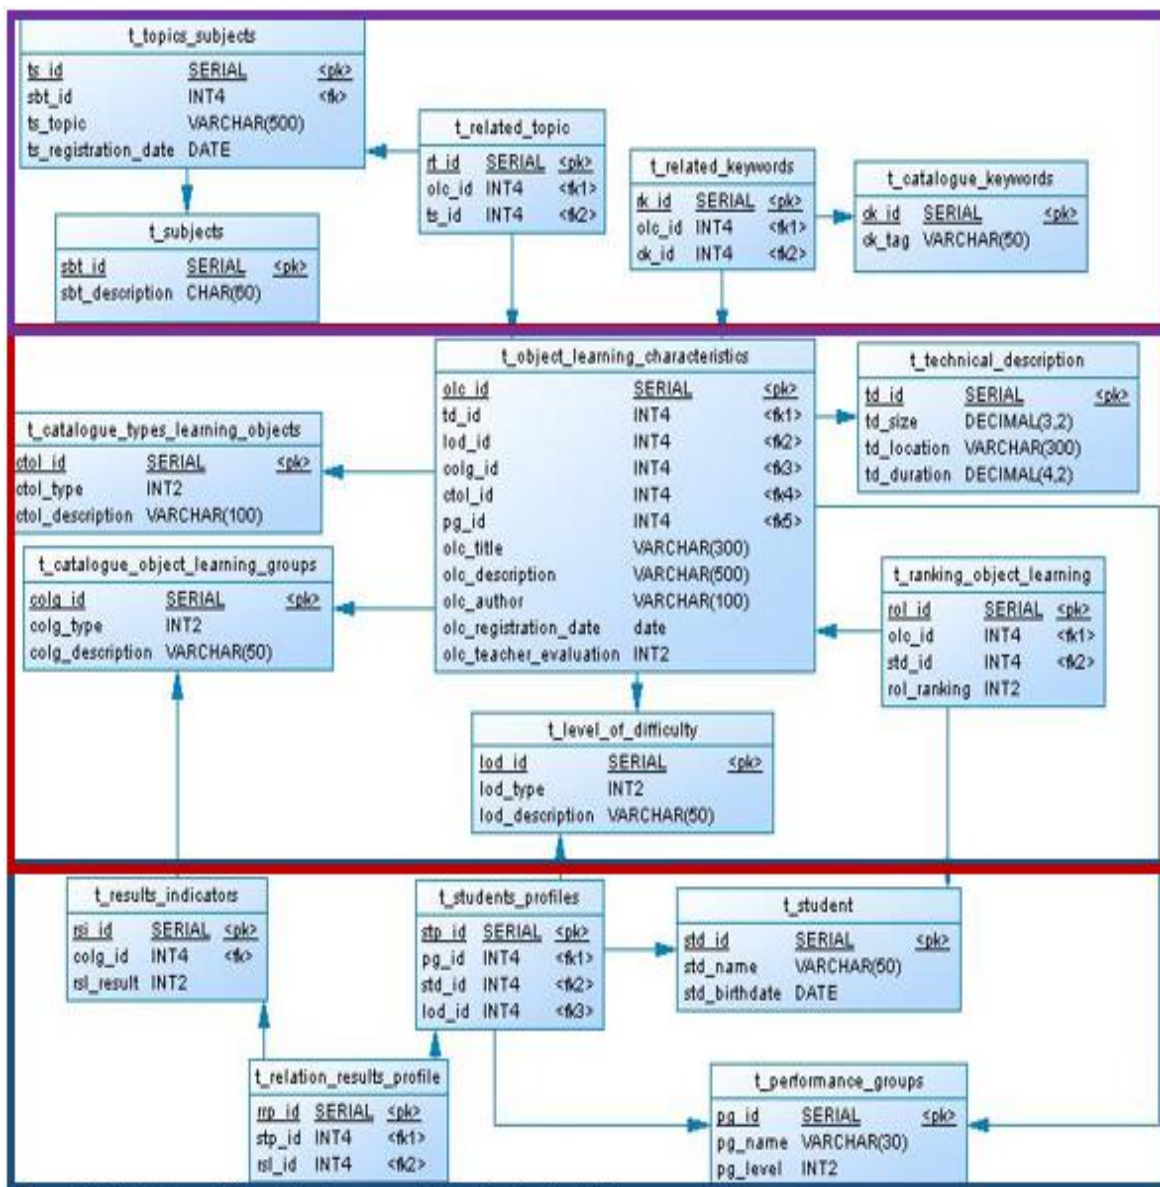


Figura 24: Modelo relacional de datos para repositorio de OA

Fuente: Bryan Arellano

- **Área roja:** almacenan las características de los OA que registran aspectos como tamaño, palabras clave con las que se relaciona (física, matemática, ecuaciones, por ejemplo), tamaño, ubicación, tipo de OA, título, grupo de aprendizaje al cual pertenece, nivel de dificultad que presenta, valoraciones que demuestran que tan útil le ha sido a cada usuario que lo ha usado entre otras.

- **Área azul:** almacena los datos de los perfiles de estudiantes, los cuales contienen características particulares de aprendizaje de cada alumno, es decir, el tipo de aprendizaje al cual un alumno se orienta más basado en el test ILS (adaptado).
- **Área púrpura:** almacena los datos de las materias a las que se asocia cada OA, es decir, el tema o contenido de una clase a la que cada objeto se asocia; visto desde otro punto de vista, el registro de cada OA con respecto al tema en el cual se utilizó como recurso.

Como consecuencia cada área corresponde a una fuente de información necesaria para distribuir OA de manera personalizada y acorde al contenido de la clase en que se requiera.

A partir de este modelo de datos se diseñaron el conjunto de servicios requeridos por el agente de recomendación. Estos servicios fueron implementados a través de un API REST⁸ utilizando Django REST framework⁹, el cual se basa en el estilo arquitectónico modelo-plantilla-vista (MTV del inglés Model-Template-View), en específico, en este framework se conoce como modelos (entidades o estructuras de la base de datos), serializador y vistas. El manejo y distribución de los datos es administrado por estos servicios, los cuales permiten al agente recomendador solicitar los datos necesarios para poder realizar sus cálculos y generar las recomendaciones.

Las principales fuentes de información del agente son:

- Información de los estilos de aprendizaje del estudiante, en este caso llamado perfil de estudiante, un ejemplo de estos datos en formato JSON se muestra en la Figura 25.

⁸ Interfaz empleada entre sistemas que usan HTTP, para poder obtener datos o generar operaciones sobre esos datos en todos los formatos posibles, como XML y JSON.

⁹ Web Framework basado en Python de código abierto y alto nivel, que facilita el desarrollo rápido y diseño limpio y pragmático para desarrollo WEB. (Django Software Foundation, s.f.)

```
[
  {
    "pg": {
      "pg_name": "Bajo",
      "pg_level": 1
    },
    "TResultsIndicators": [
      {
        "colg": {
          "colg_type": 1,
          "colg_description": "Visual"
        },
        "rsi_result": 13
      },
      {
        "colg": {
          "colg_type": 2,
          "colg_description": "Verbal"
        },
        "rsi_result": 25
      },
      {
        "colg": {
          "colg_type": 3,
          "colg_description": "Activo"
        },
        "rsi_result": 63
      }
    ],
    "lod": {
      "lod_type": 1,
      "lod_description": "Bajo"
    }
  }
]
```

Figura 25: Ejemplo de indicadores de perfil de estudiante

Fuente: Bryan Arellano

- Listado de OA para un tema en concreto, por ejemplo, el servicio de la Figura 26 provee de la lista de OA para el tema “Sistemas operativos, definición”, dicha lista también se encuentra en formato JSON.

```
{
  "id": 1272,
  "title": "Sistemas operativos",
  "description": "",
  "author": " Abraham Silberschatz",
  "registration_date": "2020-04-27",
  "teacher_evaluation": 2,
  "idobject": 409,
  "topic": "Sistemas operativos, definición",
  "tag": "Sistemas Operativos",
  "location": "http://books.google.com.ec/books?id=ep8yAAAACAAJ&dq=Sistemas+operativos&hl=&source=gbs_api",
  "size": "46.00",
  "duration": null,
  "object_type_value": 4,
  "object_type_description": "Ejercicios",
  "level_value": "Bajo",
  "lod_type": 1,
  "colg_type": 3,
  "object_group_description": "Activo",
  "pg_level": 3,
  "pg_name": "Alto"
},
```

Figura 26: Ejemplo de objeto de aprendizaje

Fuente: Bryan Arellano

- Listado de ratings de OA (Figura 27), que de igual manera al caso anterior, se basa en un tema en concreto, en este caso existen dos fuentes de información de ratings, la primera fuente es la comunidad que ha valorado los OA y la segunda se trata de los valores de utilidad con los que se registraron los OA tal como se presentaron en la Figura 24, en el área roja.

```
{
  "id": 3760,
  "object_learning": 408,
  "student": 7,
  "ranking": 2
},
{
  "id": 3761,
  "object_learning": 408,
  "student": 8,
  "ranking": 5
},
{
  "id": 3762,
  "object_learning": 408,
  "student": 9,
  "ranking": 2
},
```

Figura 27: Ejemplo de ratings de OA

Fuente: Bryan Arellano

Para eliminar la complejidad de estructuras anidadas, propias de la estructura del JSON, las cuales pueden poseer demasiadas ramificaciones o niveles de profundidad (figura 25) fue necesario crear un conjunto de vistas en la base de datos y usarlas como fuente de información en los servicios. Por ejemplo, se generaron vistas para los listados de OA. En el caso del perfil de estudiante, el modelo de datos impide generar una vista que resulte sencilla, por eso el JSON de este servicio posee varios niveles de profundidad, tal como se mostró en la figura 25.

Adicionalmente, así como existen servicios de consulta, también existen servicios de creación de nuevos datos (generación datos), para ello se desarrollaron un conjunto de servicios REST para procesar este tipo de solicitudes, las cuales se implementan a través de peticiones de una URL (POST) en la cual se le envíe la información a registrar. Ejemplos de estos tipos de servicios son, en el caso del agente recomendador, cuando se requiere actualizar un rating de un OA evaluado por un estudiante o también cuando se genera un nuevo perfil de estudiante (función que no corresponde directamente al agente); en este caso

se simula este proceso para observar el comportamiento del agente ante un nuevo estudiante en el sistema.

2.7.2 Agente recomendador

Dado que el objetivo del agente es dar un conjunto de recomendaciones híbridas a cada estudiante basándose en los estilos de aprendizaje de cada uno y dado que se requería de un formato de comunicación flexible (para la implementación se usa el formato JSON), la estructura del agente se divide en dos componentes: MatrixGenerator y RecommenderEngine.

Para la construcción se decide que debido a que se trata de un componente orientado a la Web se usaría el lenguaje PHP, desarrollado bajo el gestor de dependencias Composer¹⁰ como una librería (ver Figura 28)..

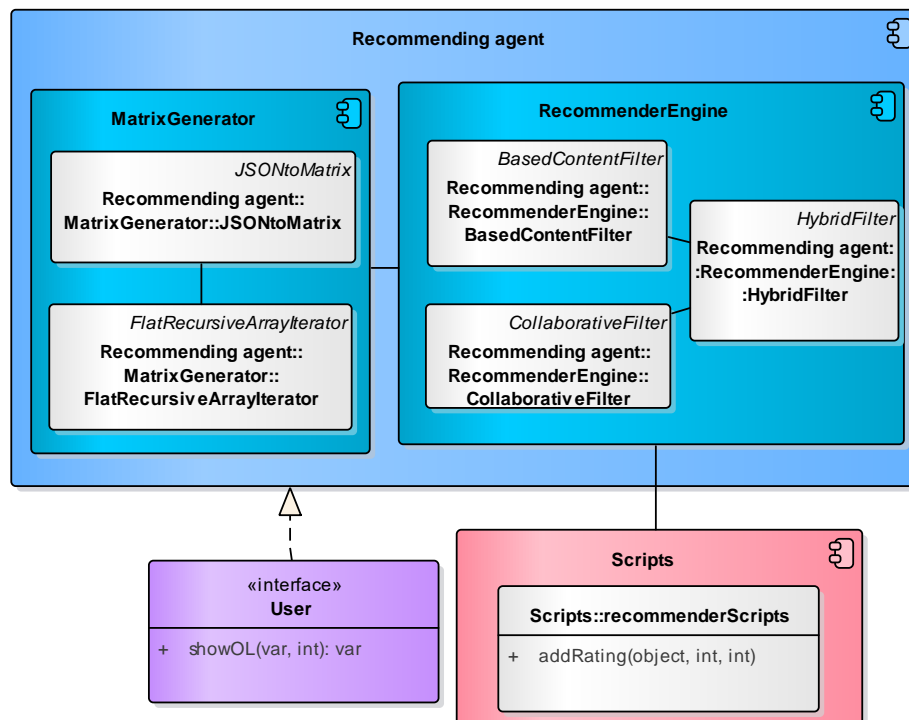


Figura 28: Componentes del agente recomendador

Fuente: Bryan Arellano

¹⁰ Composer es una herramienta para la administración de dependencias en PHP, pero no en el mismo sentido que Yum o Apt., permite declarar las librerías o paquetes de las que depende un proyecto y las gestionará (las instalará/actualizará), sin embargo, los gestiona por proyecto. (Adermann & Boggiano, s.f.)

2.7.2.1 Generador de matrices

El componente MatrixGenerator es quien inicia el proceso de recomendación, este componente tiene la responsabilidad de transformar los datos que ingresan con formato JSON en un conjunto de datos organizados en una estructura de matrices, con el objetivo de tener estructuras de fácil manipulación, que permita, de forma sencilla, realizar los cálculos requeridos por las técnicas de recomendaciones utilizadas en este proyecto. La especificación al detalle de este componente se especifica en la Figura 29.

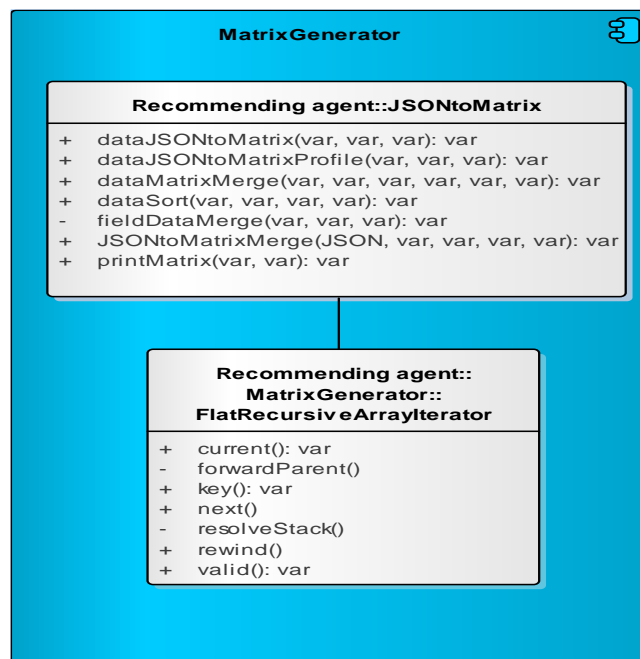


Figura 29: Clases de MatrixGenerator

Fuente: Bryan Arellano

A través de esta transformación se puede definir cuáles serán los atributos necesarios para la toma de los datos. Por ejemplo, la información que ingresa del perfil de un estudiante en una estructura compleja de varios niveles (anidada) se transforma en una estructura en forma de matriz más sencilla y mejor distribuida.

pg_level	lod_type	colg_type	rsi_result
3	1	1	50
3	1	2	30
3	1	3	20

Figura 30: Matriz de perfil de estudiante

Fuente: Bryan Arellano

Como se puede observar, en la Figura 30, los atributos de la matriz del perfil de estudiante, contienen los indicadores de los estilos de aprendizaje que el estudiante posee (colg_type, indica el tipo de estilo de aprendizaje y rsi_result el grado de tendencia que posee el estudiante con respecto al estilo), así como su grupo de desempeño (pg_level) y el nivel de dificultad de OA al que está sujeto el estudiante (lod_type).

Por otro lado, las valoraciones de los OA, generalmente llamados rating, pasan a agruparse en una sola matriz, la cual contiene todos los ratings de los OA de manera ordenada, esta agrupación se basa en el valor de utilidad que el docente le da al momento a cada OA cuando éste está ingresando el recurso didáctico. Es decir, el docente le asigna un primer rating al OA evitando que éste sea omitido por el agente recomendador al momento de realizar los cálculos, esto reduce el efecto del arranque en frío que poseen las técnicas de recomendación colaborativa. A partir de estas valoraciones (rating) se tienen dos listas de valoraciones de OA, la primera que posee todos los ratings dados por la comunidad (estudiantes) a un grupo de OA y una segunda lista que contiene los valores de utilidad (ratings iniciales) con los que los OA fueron registrados. Como las dos estructuras son distintas entre sí, se debe realizar una transformación para obtener una sola matriz con una estructura consistente y que contenga todos los ratings de los OA tal como se muestra en la Figura 31.

object_learning	id	ranking
312	1	4
312	7	4
312	8	1
312	9	1
312	10	4
312	11	1
312	12	3
312	13	2
313	1	5
313	7	5
313	8	5
313	9	1
313	10	2
313	11	4
313	12	4
313	13	1
313	14	2
313	15	4
313	16	3

Figura 31: Matriz de ratings de OA

Fuente: Bryan Arellano

Como ya se dijo el listado de OA (Figura 26), tiene una estructura sencilla y de fácil acceso, aparentemente no requiere de que se transforme a una matriz como sucede con las otras fuentes de información. Sin embargo, cuando se va a realizar la implementación del componente, se observa que la plataforma a utilizar, en este caso Django envía objetos duplicados; sin embargo, para realizar una combinación previa a la presentación de la información requerida, se requiere de procesos adicionales para poder llegar a obtener un conjunto de datos sin duplicados.

Las matrices de OA presentan duplicados debido al campo (atributo) llamado tag (ver Figura 32), en este campo se almacenan las palabras clave con la que el recurso puede ser recuperado, es decir es la palabra que describe correctamente el recurso. Un recurso puede contener varios tag, por ende, los mismos OA con varios tags son recuperados como si se tratara de distintos OA, esto genera un inconveniente ya que al momento en el que se quiera traer la información de un OA se recuperaran varias veces el mismo OA. Es por ello que una transformación a la lista de OA es necesaria, la transformación elimina los OA duplicados y los combinan en uno solo, de tal manera que el resultado final es una lista limpia de OA únicos que contiene los atributos que se requieran.

idobject	title	tag	location
312	Cómo programar en C/C++ y Java	Computadoras, Programación	http://books.google.com.ec/books?id=sWjcMGUAnXwC&dq= Sistemas+de+numeraci%C3%B3n:+decimal,+binario,+
313	SISTEMAS OPERATIVOS MONOPUESTO	Computadoras	https://play.google.com/store/books/details?id=4zjxk81LgKIC&source=gbs_api
314	Introducción a los sistemas de numeración	Programación, Computadoras	http://books.google.com.ec/books?id=L_bntgAACAAJ&dq= Sistemas+de+numeraci%C3%B3n:+decimal,+binario,+he
315	Operaciones auxiliares de montaje de componentes informáticos	Computadoras	https://play.google.com/store/books/details?id=N9GgbaYTiyIC&source=gbs_api
316	Sistemas electrónicos digitales	Programación, Computadoras	http://books.google.com.ec/books?id=V7JpKkZaEYMC&dq= Sistemas+de+numeraci%C3%B3n:+decimal,+binario,+h

Figura 32: Matriz de OA

Fuente: Bryan Arellano

Como resultado, el componente MatrixGenerator genera estructuras de datos que son consistentes para los cálculos que se realizan en el proceso de recomendación, de tal manera que las clases a cargo estos cálculos se desempeñan de forma más eficiente, ya que no necesitan verificar la coherencia y consistencia de las estructuras que reciben ni tampoco necesitan buscar los datos dentro de estructuras complejas.

2.7.2.2 Motor de recomendaciones

El motor de recomendaciones está compuesto de tres clases encargadas de aplicar los algoritmos de los filtros utilizados por el agente, estos son: colaborativo, basado en contenido e híbrido. Estas clases están diseñadas de tal manera que trabajen con las matrices generadas (MatrixGenerator) y de igual manera retornen matrices que son usadas para realizar más cálculos o para mostrarlas al usuario (estudiante). Además, este componente cuenta con una función externa que le permite actualizar los ratings que posea un OA, a través de un servicio REST tal como se especifica en el diagrama de componentes de la Figura 33. A continuación, se describen, en forma detallada, cada uno de los filtros utilizados en este trabajo.

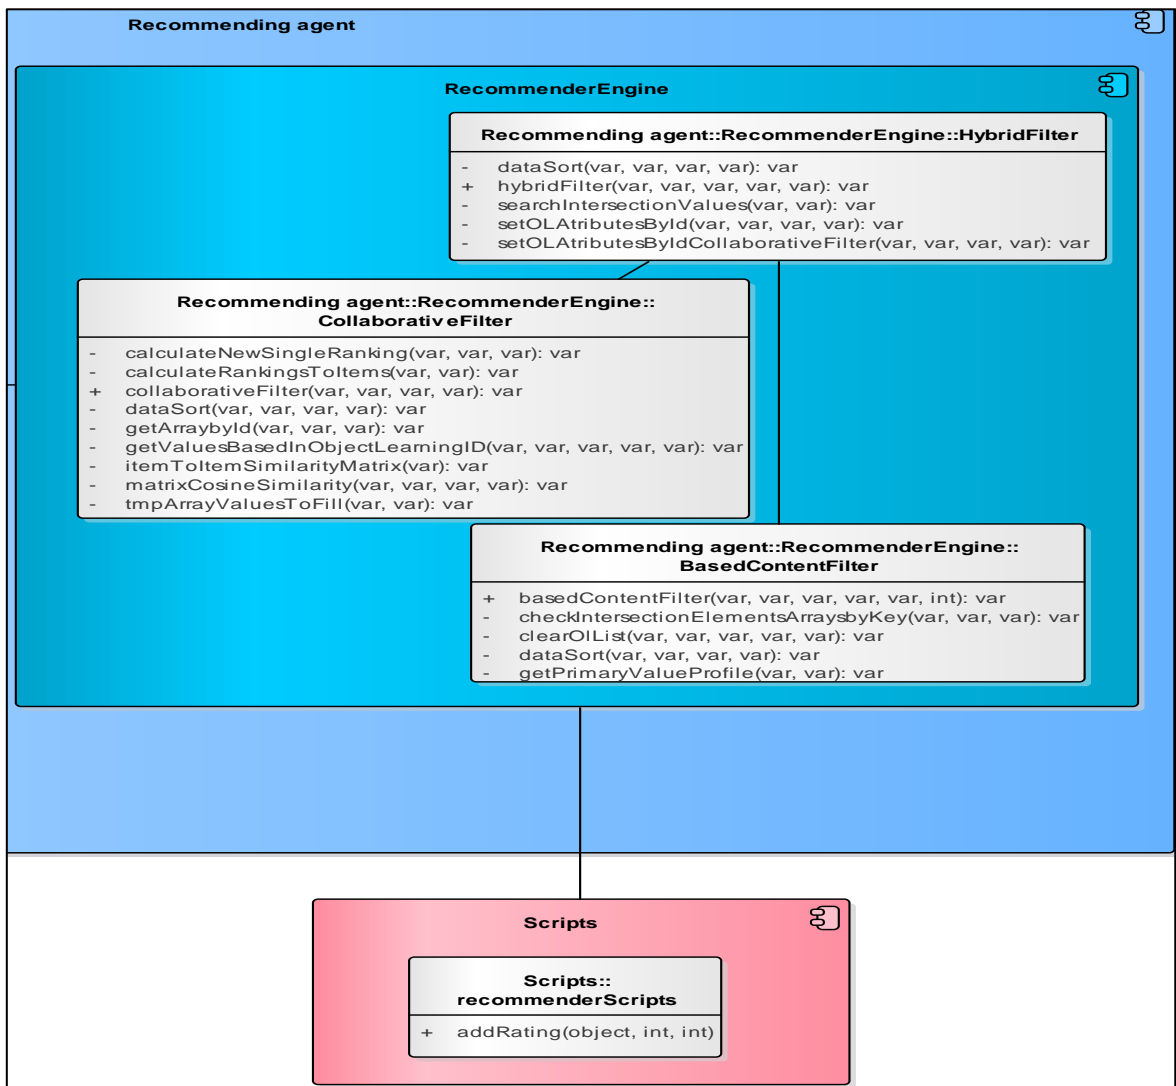


Figura 33: Clases de RecommenderEngine

Fuente: Bryan Arellano

2.7.2.2.1 Filtro colaborativo

Existen varios algoritmos de filtros colaborativos que pueden ser utilizados en los motores de recomendación. En el caso particular de este proyecto, el objetivo del filtro colaborativo es trabajar con similitudes entre las valoraciones (ratings) de usuarios con respecto a cada ítem u OA. Existen dos algoritmos que permiten satisfacer este objetivo: Pearson y similitud de coseno, de los cuáles la similitud de coseno posee los mejores resultados en cuanto a las medidas de similitudes entre elementos, al comparar las opiniones de los usuarios con respecto a los artículos o ítems usando vectores de clasificación entre el usuario objetivo y otros usuarios.

Inicialmente, el algoritmo de similitud de coseno requiere, como entrada, una matriz de ratings, la misma es solicitada al generador de matrices (Figura 31), este paso está entonces cubierto y puede ser obviado por la clase, ya que este parámetro es obtenido a través de una petición al componente responsable de generar la matriz.

Para efectos del filtro, el primer paso requiere convertir la matriz de ratings en una matriz de la forma usuario-ítem que almacene el rating de un usuario i a un OA j tal como se muestra en la Figura 34.

	OA1	OA2	OA3
U1	2	?	3
U2	5	2	?
U3	3	3	2
U4	?	2	2

Figura 34: Matriz rating usuario-ítem

Fuente: Bryan Arellano

El signo de interrogación de la figura representa la ausencia de un rating del usuario con respecto a un ítem (al momento de la implementación se utiliza espacios en blanco ya que resulta más práctico).

Posteriormente se forma una matriz de similitud ítem-a-ítem, utilizando la medida de similitud de coseno, este proceso se lleva a cabo al emplear la siguiente fórmula.

$$SimCos(d_q, q) = \frac{\sum_{n=1} (P_{(n,d)} * P_{(n,q)})}{\sqrt{\sum_{n=1} (P_{(n,d)})^2 * \sum_{n=1} (P_{(n,q)})^2}}$$

La fórmula establece que se debe ir formando vectores de ítems entre usuarios y calcular el ángulo que existe entre estos vectores. Por ejemplo, con la información de la Figura 34 se realiza lo siguiente:

- Iniciamos con los ítems OA1 y OA2, encontrando los puntos en los cuales los dos posean ratings en común, en este caso coinciden con los usuarios U2 y U3. Estos ratings en común forman el numerador de la fórmula de similitud, de tal manera que se obtendría: $(5*2) + (3*3)$.
- Ahora el denominador estará conformado por todos los ratings que posean los usuarios que estamos utilizando como medida, es decir, tomamos toda la fila de valores correspondientes a U2 y U3, como resultado se obtiene: $(\sqrt{5^2 + 2^2} * \sqrt{3^2 + 3^2 + 2^2})$.
- Como resultado final se obtiene la fórmula:
 - $SimCos(U1, U2) = \frac{(5*2) + (3*3)}{\sqrt{5^2+2^2*\sqrt{3^2+3^2+2^2}}}$
- Este proceso se repite hasta que todos los ángulos entre ítems hayan sido calculados, es decir, que todas las combinaciones posibles se hayan cubierto.
- Como resultado final se obtiene una matriz de similitud ítem-a-ítem que se muestra en la Figura 35.

	OA1	OA2	OA3
OA1	1	0.75221720334165	0.7095748751869
OA2	0.75221720334165	1	0.75377836144441
OA3	0.7095748751869	0.75377836144441	1

Figura 35: Matriz ítem-a-ítem

Fuente: Bryan Arellano

Utilizando la matriz de ítem-a-ítem, se procede a calcular las valoraciones de usuarios con respecto a ítems que todavía no han valorado, es decir, se calcula la medida de similitud entre el ítem destino y los otros ítems que el usuario ya ha calificado. Por ejemplo, si tomamos al usuario U1 con respecto al ítem OA2 (figura 34), lo primero es ubicarse en la fila OA2 de la matriz de ítem-a-ítem, luego ubicar las valoraciones que el usuario U1 ya haya dado. En este caso, él ya ha valorado los ítems OA1 y OA3, por lo que el rating se calcularía de la siguiente manera:

$$rating = \frac{2 * 0.7522 + 3 * 0.7537}{0.7522 + 0.7537} = 2.5004$$

La clase CollaborativeFilter funciona bajo estas reglas, empleando una matriz inicial que contiene los ratings de la comunidad con respecto a un tema, realiza paso a paso los cálculos que se han descrito en los párrafos anteriores. Al final la clase retorna una estructura de datos (matriz) que contiene las predicciones de ratings de un usuario, La Figura 36 muestra el diagrama de clases del filtro colaborativo del agente recomendador.



Figura 36: Clase de filtro colaborativo

Fuente: Bryan Arellano

2.7.2.2.2 Filtro basado en contenido

Para realizar una recomendación basada en contenido se requiere definir cuáles son los indicadores que deben buscarse en un ítem u objeto a recomendar, y posteriormente utilizar la información del perfil objetivo y compararlos.

En este caso, el objetivo es proveerle al usuario (estudiante) de recursos didácticos (OA) que se ajusten a los indicadores de su perfil, siendo estos indicadores su estilo de aprendizaje, grupo de desempeño y nivel de dificultad de OA, para esto se requieren de dos matrices: perfil de estudiante (Figura 30) y la de lista de OA (Figura 31).

Para el agente recomendador el estilo de aprendizaje es la prioridad, por lo cual el filtro colaborativo toma en consideración el estilo en el que el estudiante tenga una mayor tendencia, es decir, el o los valores que representen un mayor rango de tendencia. Por ejemplo, un estudiante que posee sus estilos definidos por los siguientes valores: visual 50%; verbal: 50% y activo:0%, con estos valores el filtro basado en contenido tomará en consideración, como indicadores para su búsqueda, los dos estilos predominantes del estudiante, de tal manera que al final el usuario obtenga recomendaciones que se ajusten a estos dos estilos.

La lista de OA tiene atributos que describen a que estilo de aprendizaje, grupo de desempeño y nivel de dificultad pertenecen, La clase BasedContentFilter tiene las siguientes responsabilidades, buscar en la esta lista todos los OA los que cumplan con las características que satisfagan al perfil de estudiante, descartando todas aquellas que no encajan. Finalmente, se obtiene una lista de recursos que son compatibles con el perfil del estudiante. En el caso de que ninguno de los objetos cumpla con las características del estudiante, el filtro basado en contenido toma la decisión de retornar una lista de OA que solamente se ajusten a su estilo de aprendizaje, ignorando el resto de indicadores; de esta manera se asegura que no se retorna una lista de recomendaciones vacía. La especificación de este filtro se muestra en el diagrama de clases de la Figura 37.



Figura 37: Clase de filtro basado en contenido

Fuente: Bryan Arellano

2.7.2.2.3 Filtro híbrido

El filtro híbrido se encarga de la combinación de los resultados obtenidos en los dos filtros anteriores, de tal manera que se obtienen recomendaciones ordenadas por los ratings del filtro colaborativo y que se ajusten al perfil del estudiante, basado en los resultados del filtro basado en contenido. Es decir, cada OA que no se ajuste a los indicadores del perfil y se encuentre en la lista del filtro colaborativo es descartado, como resultado final la lista de OA se ve reducida hasta el punto en el que solo se encuentren OA compatibles con el usuario. El diagrama de clases de este filtro se muestra en la Figura 38.




Figura 38: Clase de filtro híbrido

Fuente: Bryan Arellano

2.7.2.3 Despliegue de recomendaciones

Al concluir con el proceso de cálculos de recomendaciones, el resultado final es una estructura de datos (matriz) que contiene la información que se requiera mostrar al usuario, como el título del recurso, enlace, estilo de aprendizaje, entre otros. Estos atributos dependen de lo que se necesite mostrar, ahora bien, como presentar esta información es decisión de quién use el agente, en este caso se despliega en forma de una lista que le permite al usuario actualizar los ratings de los OA que visualice. Como resultado la manera en que se visualizan las recomendaciones es ajena al agente en cuestión.




Figura 39: Interfaz de visualización de recomendaciones

Fuente: Bryan Arellano

2.7.3 Escenario de pruebas

Para poder validar si el agente realiza las recomendaciones deseadas, se requiere de un escenario de prueba en el cual se pueda evidenciar y comprobar su comportamiento. En este caso el escenario de prueba se diseñó basado en un Aula Virtual, es decir, se desarrolló una plataforma Web que simule un Aula Virtual en funcionamiento y en ella incorporar el agente recomendador.

El escenario de prueba consta inicialmente de 16 perfiles de estudiantes, los perfiles se construyeron a partir de un cuestionario modificado de ILS, dichos cuestionarios fueron realizados a estudiantes seleccionados al azar con el fin de obtener perfiles que se aproximen de mejor forma a un conjunto de estudiantes reales. El ambiente de prueba brinda la posibilidad de agregar nuevos usuarios al escenario.

Los usuarios están registrados a las materias Introducción a la Computación y Matemáticas, con dos y tres temas predefinidos para cada asignatura respectivamente, en este escenario se pueden apreciar las estadísticas o indicadores del perfil del estudiante, de esta manera se puede validar si las recomendaciones que se le muestran a los estudiantes son las adecuadas para su perfil. Cabe recalcar que los indicadores de grupo de desempeño y nivel de dificultad son generados al azar, es decir, que estos atributos se generan al azar cuando se registra al usuario en la plataforma. La Figura 40 muestra la página principal del aula virtual o ambiente de prueba que se desarrolló.

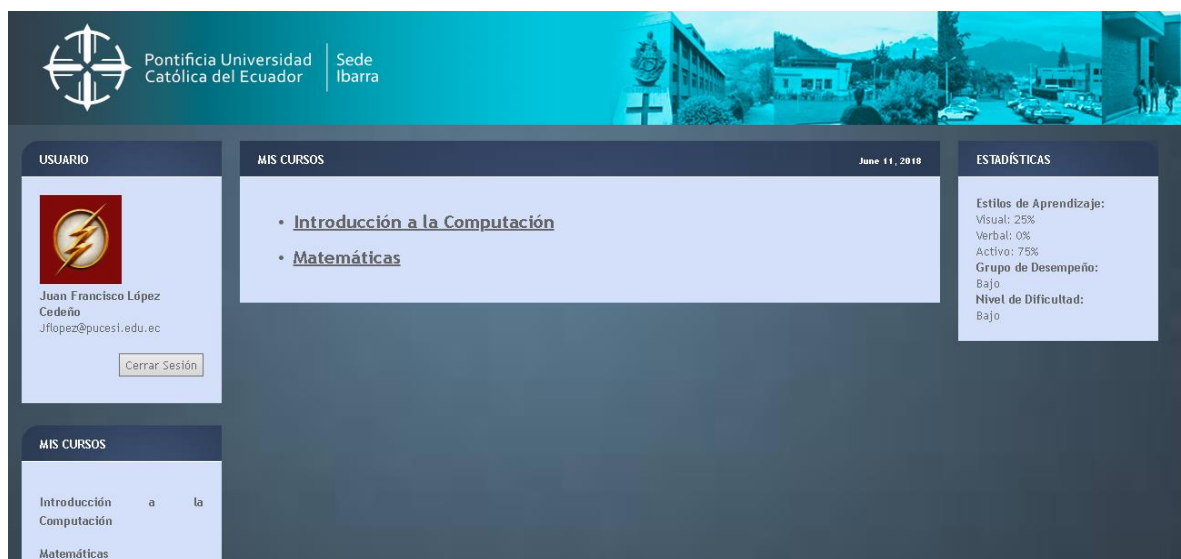


Figura 40: Escenario de pruebas - Usuarios registrados

Fuente: Bryan Arellano

En el caso de ser un nuevo usuario en lugar de mostrar las asignaturas se despliega el cuestionario ILS para que sea resuelto antes de poder generar recomendaciones, tal como se muestra en la Figura 41.



The screenshot displays the user interface of the Pontificia Universidad Católica del Ecuador. At the top, the university's logo and name are visible, along with the location 'Sede Ibarra'. The main navigation bar includes 'USUARIO', 'MIS CURSOS', 'June 11, 2018', and 'ESTADÍSTICAS'. The user profile section on the left shows the name 'Dulce Rivero' and email 'Dmrivero@pucesi.edu.ec', with a 'Cerrar Sesión' button. Below this, a message states: 'Antes de ver tus asignaturas debes llenar el cuestionario'. The central area is titled 'Test de Estilo de Aprendizaje' and contains two questions with radio button options:

- * Entiendo mejor algo:
 - a través de imágenes, diagramas, gráficas o mapas.
 - con instrucciones escritas.
 - si lo practico.
- * Cuando estoy aprendiendo algo nuevo, me ayuda:
 - una imagen.

Figura 41: Escenario de pruebas - Usuario nuevos

Fuente: Bryan Arellano

Este escenario permite identificar los posibles errores y registrar el comportamiento que tiene el agente ante cada perfil de estudiante.

CAPÍTULO III

RESULTADOS

3.1 Pruebas unitarias

A lo largo de la construcción del agente de recomendación propuesto en este trabajo, fue necesario realizar un conjunto de pruebas a cada clase que conforma al agente. Para ello, se realizaron un conjunto de pruebas de caja blanca, es decir, pruebas estructurales destinadas a comprobar que el código hacía correctamente lo que los diseños iniciales indican, con el fin de validar su correcto funcionamiento y observar posibles errores de programación.

3.1.1 Pruebas de generador de matrices

En este caso las pruebas se iniciaron por las clases que están a cargo de la transformación de los datos en formatos JSON a estructuras de matrices, se utilizaron los siguientes casos de pruebas:

- Transformación y combinación de dos fuentes de información JSON que posean la misma estructura.
- Combinación de objetos duplicados en una sola estructura basados en un único campo clave.
- Creación de matrices sin combinar objetos duplicados.
- Generación de matrices basadas en fuentes JSON con varios niveles de profundidad.
- El retorno de estructuras ordenadas por un valor clave (Como se puede apreciar en el apartado 2.7.2.1).

Como resultado de las pruebas para las clases del componente MatrixGenerator, se observó que podía generar las matrices correctamente a partir de objetos de tipo JSON, utilizando campos claves para generar matrices de estructuras menos complejas y de fácil acceso a sus datos. Es decir, el componente requiere que se le indique cuáles son los campos de los cuáles va a obtener los datos, o cuáles debe usar como campos clave para ordenar o buscar valores para generar las nuevas estructuras. A partir de esto, el componente sujetó a pruebas con objetos de hasta tres niveles de profundidad (figura 25) puede generar, de forma correcta,

las matrices de fuentes de datos JSON. Sin embargo, es importante decir que las pruebas se realizaron con un sujeto de prueba de hasta tres niveles de profundidad, tal como el que se mostró en la figura 25, por lo que no se puede garantizar si a una mayor complejidad (niveles de profundidad o ramificaciones) del objeto JSON puede afectar su funcionamiento.

3.1.2 Pruebas de motor de recomendación

Para validar el funcionamiento del motor de recomendación o RecommenderEngine se probó, cada clase que aplica un filtro de recomendación; para la prueba se aplicaron los principios explicados con anterioridad en el apartado 2.7. Es decir, que los valores que retornen los filtros, una vez finalizado los cálculos, deben concordar con cada uno de los fundamentos a los que está asociado.

3.1.2.1 Pruebas de filtro colaborativo

El filtro colaborativo, debe retornar una estructura que contenga los resultados del cálculo de similitud de coseno, para comprobar que esta clase funciona correctamente se requirieron de cálculos realizados manualmente (valores esperados). estos valores sirven para corroborar que éstos resultados obtenidos en las pruebas concordaban con los resultados que se esperaban obtener.

Un caso de prueba es el siguiente: usando los datos del apartado 2.7.2.2.1 la clase debe hacer los cálculos exactamente iguales a los valores esperados, en este caso, se verifica que la estructura de los resultados de las matriz ítem-a-ítem coincida con los valores del ejemplo. Los resultados obtenidos se muestran en la figura 42.

```

"Array
(
  [0] => Array
  (
    [0] => 1
    [1] => 2
    [2] => 3
  )

  [1] => Array
  (
    [id] => 1
    [0] => 1
    [1] => 0.75221720334165
    [2] => 0.7095748751869
  )

  [2] => Array
  (
    [id] => 2
    [0] => 0.75221720334165
    [1] => 1
    [2] => 0.75377836144441
  )

  [3] => Array
  (
    [id] => 3
    [0] => 0.7095748751869
    [1] => 0.75377836144441
    [2] => 1
  )
)

```

Figura 42: Resultados de cálculos para matriz ítem-a-ítem

Fuente: Bryan Arellano

Estas pruebas son de unidad, las pruebas funcionales permiten verificar si los resultados definitivos, el resultado de la predicción, que es lo que retorna la clase como tal, coincide con los resultados esperados. Para esta prueba se verifico que todos los ratings que el usuario ha dado sean regresados en una matriz, incluyendo los ratings que se han generado por medio de los cálculos de similitud de coseno, además, debían incluir el identificador de OA al que pertenece.

```

Array
(
  [0] => Array
  (
    [ranking] => 2
    [0] => 1
  )

  [1] => Array
  (
    [ranking] => 2.5
    [0] => 2
  )

  [2] => Array
  (
    [ranking] => 3
    [0] => 3
  )
)

```

Figura 43: Predicciones de ratings generadas por el filtro colaborativo

Fuente: Bryan Arellano

Como se puede apreciar, los resultados de los cálculos de similitud de coseno realizados por la clase del filtro colaborativo (Figura 43), se realizan de manera correcta, coincidiendo lo que se había explicado anteriormente.

3.1.2.2 Pruebas de filtro basado en contenido y filtro colaborativo

En el caso de los filtros basado en contenido e híbrido, sus pruebas se centraron en observar los resultados obtenidos por los filtros, con el objeto de validar que la búsqueda y comparación de datos en el filtro es correcta. Es decir, sus resultados son las listas generadas por una recomendación.

Se comenzó con el filtro basado en contenido, su función principal es la de retornar una lista que contenga todos los objetos que posea los mismos indicadores que el perfil del estudiante o al menos su mismo estilo de aprendizaje. Una vez que esto sucede, el filtro híbrido utiliza esta información para interceptar los OA en común que se encuentren en la lista del filtro colaborativo y la del filtro basado en contenido y descartar el resto de OA, de manera tal que emplea los ratings del filtro colaborativo para ordenar las recomendaciones de manera descendente y la información del filtro basado en contenido para descartar aquellos OA que no son compatibles con el usuario.

TEMAS DEL DÍA June 12, 2018 ESTADÍSTICAS

Tus Recomendaciones

Clic en el título para ver los detalles

Cómo programar en C/C++
★★★★★

Ver Recurso

Estilo de Aprendizaje: Activo	Tipo de Recurso: Ejercicios	Grupo de Desempeño: Bajo	Nivel de Dificultad: Bajo
-------------------------------	-----------------------------	--------------------------	---------------------------

Tags: Programación, Sistemas Operativos, Computadoras, Tecnología, Matemáticas

Estilos de Aprendizaje:
Visual: 13%
Verbal: 25%
Activo: 63%

Grupo de Desempeño: Bajo

Nivel de Dificultad: Bajo

Figura 44: Resultados de filtro híbrido

Fuente: Bryan Arellano

3.2 Pruebas de integración en el escenario de prueba

Como ya se había explicado, el escenario de pruebas establecido sería en una plataforma de Aula Virtual que permita hacer las simulaciones con los 16 estudiantes registrados. Aunque se tiene la posibilidad de ingresar nuevos usuarios, es decir, observar el comportamiento del agente al integrarlo en una plataforma.

Los resultados obtenidos se registraron utilizando la información de los indicadores del perfil de los estudiantes con respecto al número de recomendaciones realizadas por el agente para un tema determinado, es decir, se tomaron en cuenta el total de recomendaciones que el agente presentó ante cada perfil y a partir de estas recomendaciones se verificó el porcentaje de coincidencias con respecto a los indicadores de estilos de aprendizaje, grupo de desempeño y nivel de dificultad. Por ejemplo, si a un perfil se le presentaban 5 recomendaciones con los estilos tanto visual y activo como dominantes, con un grupo de desempeño y nivel de dificultad medio, entonces todas las recomendaciones (OA) que coincidieran con estos indicadores cumplirían un 100% de efectividad con respecto a cada indicador, disminuyendo el porcentaje a medida a que un OA no coincidiera con un indicador en específico.

Perfil	Estilos de Aprendizaje			Indicadores de Desempeño		Introducción a la Computación				
	Visual (%)	Verbal (%)	Activo (%)	Grupo de Desempeño	Nivel de Dificultad	Sistemas de numeración: decimal, binario, hexadecimal				
						Número de Recomendaciones Obtenidas	Coincidencia con Estilo/os de Aprendizaje (%)	Coincidencia con Grupo de Desempeño (%)	Coincidencia con Nivel de Dificultad (%)	
1	mgtorres@pucesi.edu.ec	0	50	50	Medio	Medio	5	100	100	100
2	jflopez@pucesi.edu.ec	25	0	75	Bajo	Bajo	2	100	100	100
3	rdbermudez@pucesi.edu.ec	37,5	25	37,5	Alto	Alto	15	100	100	100
4	aaleon@pucesi.edu.ec	12,5	0	87,5	Medio	Alto	5	100	100	100
5	jdjaramillo@pucesi.edu.ec	50	0	50	Bajo	Medio	4	100	100	100
6	eljaramillo@pucesi.edu.ec	25	0	75	Bajo	Bajo	2	100	100	100
7	frlopez@pucesi.edu.ec	37,5	25	37,5	Bajo	Medio	6	100	100	100
8	fmcastillo@pucesi.edu.ec	0	12,5	87,5	Medio	Medio	2	100	100	100
9	ncromero@pucesi.edu.ec	62,5	37,5	0	Alto	Medio	3	100	100	100
10	mdrodriguez@pucesi.edu.ec	50	25	25	Medio	Alto	12	100	100	100
11	jaromero@pucesi.edu.ec	37,5	12,5	50	Medio	Bajo	8	100	100	100
12	arleon@pucesi.edu.ec	37,5	12,5	50	Alto	Bajo	8	100	100	100
13	amjimenez@pucesi.edu.ec	12,5	37,5	50	Medio	Medio	5	100	100	100
14	daromero@pucesi.edu.ec	50	25	25	Bajo	Alto	11	100	100	100
15	vdvera@pucesi.edu.ec	75	0	25	Bajo	Alto	6	100	100	100
16	iavera@pucesi.edu.ec	50	12,5	37,5	Bajo	Alto	8	100	100	100
17	jdibagando@pucesi.edu.ec	12,5	25	62,5	Bajo	Bajo	2	100	100	100
18	lguerra@pucesi.edu.ec	62,5	37,5	0	Medio	Bajo	11	100	100	100
19	bgarellano@pucesi.edu.ec	50	30	20	Alto	Bajo	11	100	100	100

Figura 45: Resultados de recomendaciones para "Sistemas de numeración: decimal, binario, hexadecimal"

Fuente: Bryan Arellano

Perfil	Estilos de Aprendizaje			Indicadores de Desempeño		Introducción a la Computación				
	Visual (%)	Verbal (%)	Activo (%)	Grupo de Desempeño	Nivel de Dificultad	Sistemas operativos, definición				
						Número de Recomendaciones Obtenidas	Coincidencia con Estilo/os de Aprendizaje (%)	Coincidencia con Grupo de Desempeño (%)	Coincidencia con Nivel de Dificultad (%)	
1	mgtorres@pucesi.edu.ec	0	50	50	Medio	Medio	7	100	100	100
2	jflopez@pucesi.edu.ec	25	0	75	Bajo	Bajo	15	100	7	33,3
3	rdbermudez@pucesi.edu.ec	37,5	25	37,5	Alto	Alto	12	100	100	100
4	aaleon@pucesi.edu.ec	12,5	0	87,5	Medio	Alto	1	100	100	100
5	jdjaramillo@pucesi.edu.ec	50	0	50	Bajo	Medio	6	100	100	100
6	eljaramillo@pucesi.edu.ec	25	0	75	Bajo	Bajo	15	100	7	33,3
7	frlopez@pucesi.edu.ec	37,5	25	37,5	Bajo	Medio	16	100	100	100
8	fmcastillo@pucesi.edu.ec	0	12,5	87,5	Medio	Medio	1	100	100	100
9	ncromero@pucesi.edu.ec	62,5	37,5	0	Alto	Medio	10	100	100	100
10	mdrodriguez@pucesi.edu.ec	50	25	25	Medio	Alto	11	100	100	100
11	jaromero@pucesi.edu.ec	37,5	12,5	50	Medio	Bajo	6	100	100	100
12	arleon@pucesi.edu.ec	37,5	12,5	50	Alto	Bajo	9	100	100	100
13	amjimenez@pucesi.edu.ec	12,5	37,5	50	Medio	Medio	7	100	100	100
14	daromero@pucesi.edu.ec	50	25	25	Bajo	Alto	7	66,6	100	100
15	vdvera@pucesi.edu.ec	75	0	25	Bajo	Alto	1	100	100	100
16	iavera@pucesi.edu.ec	50	12,5	37,5	Bajo	Alto	1	50	100	100
17	jdibagando@pucesi.edu.ec	12,5	25	62,5	Bajo	Bajo	15	100	6,6	33,3
18	lguerra@pucesi.edu.ec	62,5	37,5	0	Medio	Bajo	8	100	100	100
19	bgarellano@pucesi.edu.ec	50	30	20	Alto	Bajo	11	100	100	100

Figura 46: Resultados de recomendaciones para "Sistemas operativos, definición"

Fuente: Bryan Arellano

Perfil	Estilos de Aprendizaje			Indicadores de Desempeño		Matemáticas				
	Visual (%)	Verbal (%)	Activo (%)	Grupo de Desempeño	Nivel de Dificultad	Ecuaciones trigonométricas				
						Número de Recomendaciones Obtenidas	Coincidencia con Estilo/os de Aprendizaje (%)	Coincidencia con Grupo de Desempeño (%)	Coincidencia con Nivel de Dificultad (%)	
1	mgtorres@pucesi.edu.ec	0	50	50	Medio	Medio	7	100	100	100
2	jflopez@pucesi.edu.ec	25	0	75	Bajo	Bajo	1	100	100	100
3	rdbermudez@pucesi.edu.ec	37,5	25	37,5	Alto	Alto	10	100	100	100
4	aaleon@pucesi.edu.ec	12,5	0	87,5	Medio	Alto	2	100	100	100
5	jdjaramillo@pucesi.edu.ec	50	0	50	Bajo	Medio	5	100	100	100
6	eljaramillo@pucesi.edu.ec	25	0	75	Bajo	Bajo	1	100	100	100
7	frlopez@pucesi.edu.ec	37,5	25	37,5	Bajo	Medio	12	100	100	100
8	fmcastillo@pucesi.edu.ec	0	12,5	87,5	Medio	Medio	1	100	100	100
9	ncromero@pucesi.edu.ec	62,5	37,5	0	Alto	Medio	8	100	100	100
10	mdrodriguez@pucesi.edu.ec	50	25	25	Medio	Alto	12	100	100	100
11	jaromero@pucesi.edu.ec	37,5	12,5	50	Medio	Bajo	4	100	100	100
12	arleon@pucesi.edu.ec	37,5	12,5	50	Alto	Bajo	8	100	100	100
13	arnjimenez@pucesi.edu.ec	12,5	37,5	50	Medio	Medio	7	100	100	100
14	daromero@pucesi.edu.ec	50	25	25	Bajo	Alto	14	66,6	100	100
15	vdvera@pucesi.edu.ec	75	0	25	Bajo	Alto	9	100	100	100
16	iavera@pucesi.edu.ec	50	12,5	37,5	Bajo	Alto	9	50	100	100
17	jdibagando@pucesi.edu.ec	12,5	25	62,5	Bajo	Bajo	1	100	100	100
18	iguerra@pucesi.edu.ec	62,5	37,5	0	Medio	Bajo	5	100	100	100
19	bgarellano@pucesi.edu.ec	50	30	20	Alto	Bajo	11	100	100	100

Figura 47: Resultados de recomendaciones para "Ecuaciones trigonométricas"

Fuente: Bryan Arellano

Perfil	Estilos de Aprendizaje			Indicadores de Desempeño		Matemáticas				
	Visual (%)	Verbal (%)	Activo (%)	Grupo de Desempeño	Nivel de Dificultad	Ecuaciones				
						Número de Recomendaciones Obtenidas	Coincidencia con Estilo/os de Aprendizaje (%)	Coincidencia con Grupo de Desempeño (%)	Coincidencia con Nivel de Dificultad (%)	
1	mgtorres@pucesi.edu.ec	0	50	50	Medio	Medio	10	100	100	100
2	jflopez@pucesi.edu.ec	25	0	75	Bajo	Bajo	4	100	100	100
3	rdbermudez@pucesi.edu.ec	37,5	25	37,5	Alto	Alto	18	100	100	100
4	aaleon@pucesi.edu.ec	12,5	0	87,5	Medio	Alto	5	100	100	100
5	jdjaramillo@pucesi.edu.ec	50	0	50	Bajo	Medio	7	100	100	100
6	eljaramillo@pucesi.edu.ec	25	0	75	Bajo	Bajo	4	100	100	100
7	frlopez@pucesi.edu.ec	37,5	25	37,5	Bajo	Medio	18	100	100	100
8	fmcastillo@pucesi.edu.ec	0	12,5	87,5	Medio	Medio	2	100	100	100
9	ncromero@pucesi.edu.ec	62,5	37,5	0	Alto	Medio	18	100	100	100
10	mdrodriguez@pucesi.edu.ec	50	25	25	Medio	Alto	24	100	100	100
11	jaromero@pucesi.edu.ec	37,5	12,5	50	Medio	Bajo	9	100	100	100
12	arleon@pucesi.edu.ec	37,5	12,5	50	Alto	Bajo	16	100	100	100
13	amjimenez@pucesi.edu.ec	12,5	37,5	50	Medio	Medio	10	100	100	100
14	daromero@pucesi.edu.ec	50	25	25	Bajo	Alto	22	100	100	100
15	vdvera@pucesi.edu.ec	75	0	25	Bajo	Alto	11	100	100	100
16	iavera@pucesi.edu.ec	50	12,5	37,5	Bajo	Alto	14	100	100	100
17	jdibagando@pucesi.edu.ec	12,5	25	62,5	Bajo	Bajo	4	100	100	100
18	iguerra@pucesi.edu.ec	62,5	37,5	0	Medio	Bajo	10	100	100	100
19	bgarellano@pucesi.edu.ec	50	30	20	Alto	Bajo	21	100	100	100

Figura 48: Resultados de recomendaciones para "Ecuaciones"

Fuente: Bryan Arellano

Perfil	Estilos de Aprendizaje			Indicadores de Desempeño		Matemáticas			
	Visual (%)	Verbal (%)	Activo (%)	Grupo de Desempeño	Nivel de Dificultad	Geometría analítica			
						Número de Recomendaciones Obtenidas	Coincidencia con Estilos de Aprendizaje (%)	Coincidencia con Grupo de Desempeño (%)	Coincidencia con Nivel de Dificultad (%)
1 mgtorres@pucesi.edu.ec	0	50	50	Medio	Medio	11	100	100	100
2 jflopez@pucesi.edu.ec	25	0	75	Bajo	Bajo	5	100	100	100
3 rdbermudez@pucesi.edu.ec	37,5	25	37,5	Alto	Alto	11	66,6	100	100
4 aaleon@pucesi.edu.ec	12,5	0	87,5	Medio	Alto	2	100	100	100
5 jdjaramillo@pucesi.edu.ec	50	0	50	Bajo	Medio	3	50	100	100
6 eljaramillo@pucesi.edu.ec	25	0	75	Bajo	Bajo	5	100	100	100
7 frlopez@pucesi.edu.ec	37,5	25	37,5	Bajo	Medio	14	66,6	100	100
8 fmcastillo@pucesi.edu.ec	0	12,5	87,5	Medio	Medio	2	100	100	100
9 ncromero@pucesi.edu.ec	62,5	37,5	0	Alto	Medio	4	50	100	100
10 mdrodriguez@pucesi.edu.ec	50	25	25	Medio	Alto	12	66,6	100	100
11 jaromero@pucesi.edu.ec	37,5	12,5	50	Medio	Bajo	4	50	100	100
12 arleon@pucesi.edu.ec	37,5	12,5	50	Alto	Bajo	5	50	100	100
13 amjimenez@pucesi.edu.ec	12,5	37,5	50	Medio	Medio	12	100	100	100
14 daromero@pucesi.edu.ec	50	25	25	Bajo	Alto	11	66,6	100	100
15 vdvera@pucesi.edu.ec	75	0	25	Bajo	Alto	10	100	30	20
16 iavera@pucesi.edu.ec	50	12,5	37,5	Bajo	Alto	2	50	100	100
17 jdibagando@pucesi.edu.ec	12,5	25	62,5	Bajo	Bajo	5	100	100	100
18 lguerra@pucesi.edu.ec	62,5	37,5	0	Medio	Bajo	8	50	100	100
19 bqarellano@pucesi.edu.ec	50	30	20	Alto	Bajo	5	50	100	100

Figura 49: Resultados de recomendaciones para "Geometría analítica"

Fuente: Bryan Arellano

Desde la Figura 45 a la Figura 49 se muestran los resultados obtenidos al ejecutar los casos de prueba con los registros de los perfiles. Lo que se encuentra resaltado en color amarillo son perfiles creados en el mismo escenario de pruebas, de esta manera se puede observar cómo se comporta el agente ante nuevos usuarios que ingresan a la plataforma.

A partir de estos registros se pudo determinar en promedio cuantas recomendaciones se presentaron a los usuarios en función del número de estilos de aprendizaje que se consideran dominantes. Para considerar a un estilo igual de dominante que otro el agente se basa en que los otros estilos deben alcanzar al menos el 50% del valor del estilo de aprendizaje más alto, por ejemplo, si un estudiante llega a ser 50% visual los otros estilos deberán ser igual o mayores que 25% para ser considerados como estilos igual de dominantes. La Figura 50 hasta la Figura 54 muestran los resultados obtenidos de estas simulaciones.




Figura 50: Promedio de recomendaciones para "Sistemas operativos, definición"

Fuente: Bryan Arellano

La Figura 50 detalla el promedio de recomendaciones obtenidas para el tema "Sistemas operativos definición", en la cual se puede apreciar que los perfiles con uno y dos estilos de aprendizaje tienden a recibir casi la misma cantidad de OA, entre siete y ocho, por otro lado aquellos que poseen tres estilos de aprendizaje reciben una mayor cantidad de OA, llegando a los doce; en los tres casos no se aprecia una diferencia notable en la cantidad de

recomendaciones, debido a que en el repositorio existen una variedad de OA que se ajustan a los perfiles que se emplearon para la prueba, es decir, las características de éstos se ajustan a varios perfiles y se puede generar una amplia gama de recomendaciones para cada perfil.

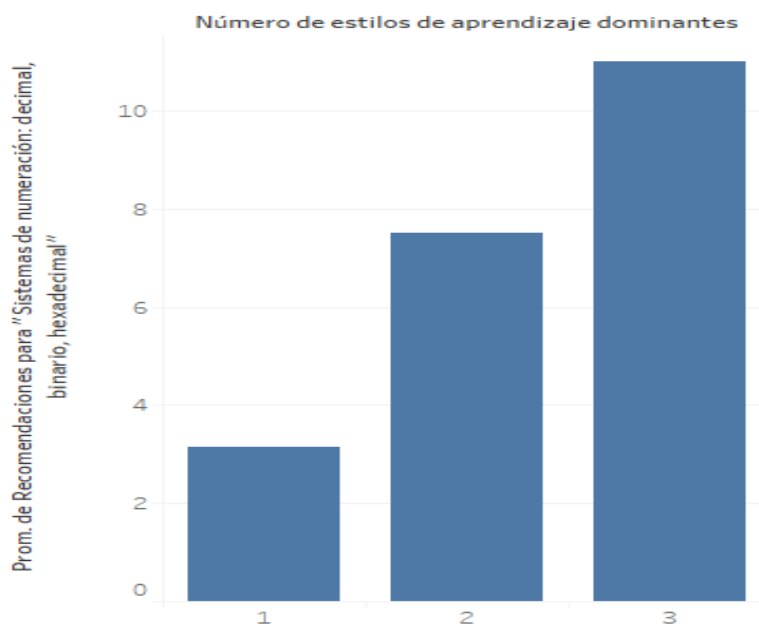


Figura 51: Promedio de recomendaciones para "Sistemas de numeración: decimal, binario, hexadecimal"

Fuente: Bryan Arellano

En el caso de la Figura 51 se puede apreciar una disminución en las recomendaciones para perfiles que poseen un solo estilo de aprendizaje, sin embargo, a medida que existen más estilos de aprendizaje el número de recomendaciones tiende a incrementar de la misma manera; esto implica que en el repositorio no existían varios OA que satisfagan a los perfiles con un solo estilo de aprendizaje, por otro lado entre más estilos de aprendizaje poseía un perfil, el rango de recomendaciones se ampliaba, pero como consecuencia se reducía el porcentaje de acierto en los estilos de aprendizaje, como se puede apreciar en la Figura 45.




Figura 52: Promedio de recomendaciones para "Ecuaciones"

Fuente: Bryan Arellano

La Figura 52, muestra un comportamiento similar al de la Figura 51, debido al incremento proporcional de recomendaciones con respecto al número de estilos de aprendizaje que poseen los perfiles.

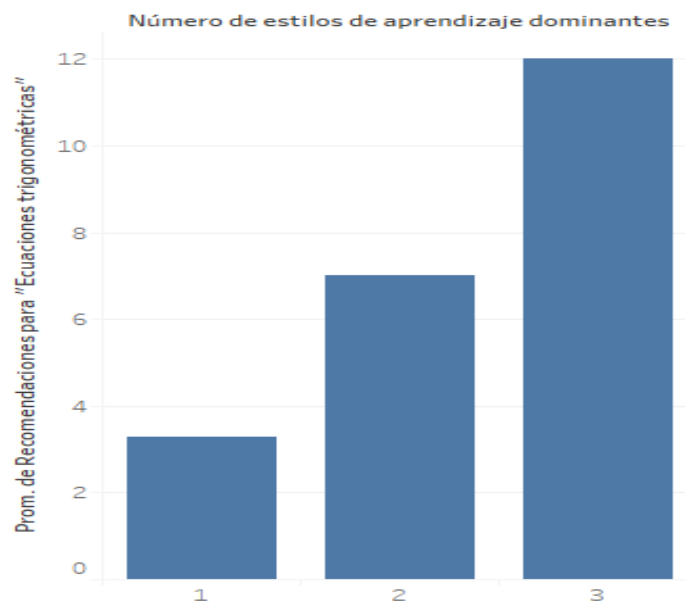


Figura 53: Promedio de recomendaciones para "Ecuaciones trigonométricas"

Fuente: Bryan Arellano




Figura 54: Promedio de recomendaciones para "Geometría analítica"

Fuente: Bryan Arellano

Finalmente, la Figura 53 y 54 indican el promedio de recomendaciones obtenidas para "Ecuaciones trigonométricas" y "Geometría analítica", respectivamente. Estos promedios muestran un comportamiento exactamente igual al de las Figuras 51 y 52; excepto que en la Figura 54, las recomendaciones generadas para los perfiles con un solo estilo de aprendizaje se acercan a las recomendaciones para dos estilos de aprendizaje.

Como resultado se puede apreciar que, entre más reducido es el número de estilos de aprendizaje dominantes, el rango de recomendaciones también disminuye debido a que se realiza una búsqueda más precisa de OA que se ajusten al perfil, por otro lado, entre mayor es el número de estilos dominantes el rango de búsqueda y recomendaciones también lo será, es decir, que la cantidad de recomendaciones obtenidas es proporcional al número de estilos de aprendizaje que posee el perfil del estudiante.

CAPÍTULO IV

CONCLUSIONES

4.1 Conclusiones

En el proyecto de tesis “Modelo de agente adaptativo al contexto para ofrecer sugerencias de recursos didácticos” se desarrolló un componente o librería en lenguaje PHP capaz de generar recomendaciones a usuarios basado en indicadores de perfil. Para validar su implementación, se creó un escenario de pruebas donde se registró el comportamiento del agente con cada perfil de estudiante registrado, a partir de los resultados obtenidos con este trabajo, se pueden dar las siguientes conclusiones.

Los resultados registrados en el escenario de pruebas determinaron que el agente tiende a mostrar en promedio un mayor número de recomendaciones cuando un usuario posee dos o más estilos de aprendizaje, sin embargo, existe una disminución en cuanto a la coincidencia con el estilo de aprendizaje esto se debe a que el agente llega a encontrar grupos de OA que cumplen con algunos de los estilos de aprendizaje del usuario incluyendo el grupo de desempeño y nivel de dificultad, pero no llega a satisfacer uno o más estilos de aprendizaje dominantes del perfil; por ejemplo si un usuario tiene tres estilos dominantes y el agente llega a recomendar OA que cumplen con dos de estos, entonces significa que ha acertado en un 66.6% (Figura 47, perfil 14) en la coincidencia de estilos.

Ahora bien, si el agente no encuentra OA que cumplan con todos los indicadores del perfil, el satisface las recomendaciones recuperando objetos que si cumplen con el o los estilos de aprendizaje dominantes del usuario, pero esto implica una disminución en la coincidencia con los indicadores de grupo de desempeño y nivel de dificultad (Figura 49, perfil 15), es decir, que el agente toma prioridad por los estilos de aprendizaje antes los otros indicadores, de tal manera que un usuario llega a obtener recomendaciones que se ajustan a su estilo pero pueden llegar a estar fuera de su grado de desempeño o nivel de dificultad; cabe recalcar que la prioridad por los estilos de aprendizaje radica en que los indicadores de grupos de desempeño y niveles de dificultad del perfil del estudiante son generados al azar, ya que esta información tendría que provenir de un agente externo encargado de evaluar el desempeño del estudiante, por lo cual estos indicadores son usados como una referencia de su respectivo agente, y representan una muestra de la influencia que tendrían en el agente recomendador

en el caso de la existencia de otro componente que pueda generar la información para estos indicadores.

Como se ha mencionado los indicadores de grupo de desempeño y nivel de dificultad son representaciones de un agente externo, pero de igual manera lo son los indicadores de estilos de aprendizaje, pero la diferencia radica en que los estilos de aprendizaje pueden ser generados inmediatamente a través del test de calibración (ILS modificado) que se le muestra a un usuario nuevo al momento en el que ingresa a la plataforma de pruebas, de esta manera se puede obtener la información para generar los resultados de su estilo o estilos de aprendizaje, por el contrario los indicadores de desempeño y nivel de dificultad requieren de un monitoreo constante del estudiante con respecto a su desarrollo a lo largo de la clase, es decir, los indicadores requieren de una constante actualización. Si bien es cierto que el test de calibración permite obtener los estilos de aprendizaje de manera inmediata, también reduce el problema de Cold-Start, es decir, el agente obtiene la información necesaria para poder generar recomendaciones, de esta manera el agente reduce las posibilidades de dejar sin recomendaciones a un usuario por falta de información para realizar los cálculos.

El funcionamiento del agente emplea matrices generadas a partir de información en formato JSON, para poder generar recomendaciones, sin embargo, la información que se empleó para generar las matrices no tenía un estructura o niveles muy complejos siendo estos entre 1 y 3 niveles de profundidad, debido a esto las limitaciones ante estructuras aún más complejas no han podido ser registradas, pero no implica que el agente no pueda ser adaptado para generar matrices y emplearlas, a partir de estructuras de información JSON más complejas; básicamente la formación de las matrices supone tener en claro cuáles serán los atributos necesarios para los cálculos de las recomendaciones, ya que el agente requiere de tres matrices fundamentales para funcionar: el perfil del estudiante (indicadores), lista de OA y la lista de ratings de los OA, de esta manera lo importante no es cuan compleja sea la fuente de información si no de que si contiene la información necesaria para realizar los cálculos de manera adecuada.

En lo que respecta al tiempo de ejecución del agente para determinar si es óptimo, las pruebas realizadas no pueden dar una respuesta ya que, para verificar su eficiencia en relación al tiempo, se requieren de miles de OA de tal manera que los límites del agente puedan ser puestos a prueba, en este caso con un repositorio que no cuenta con tantos recursos, la

velocidad con la que el agente realiza las recomendaciones no puede establecer de manera concisa si realmente es óptimo en el tiempo.

El modelo de datos que se ha propuesto para el repositorio de OA, no es un limitante para el funcionamiento del agente solo implica una base de la cual se puede partir y que de igual manera está abierto a cambios y mejoras en su diseño, ya que en principio se diseñó con la idea de que este modelo pueda ser anexado a un modelo ya existente para poder poner en funcionamiento al agente de recomendaciones.

Con respecto a los filtros empleados en el motor de recomendaciones, el filtro basado en contenido es un método de información básica, ya que requiere de emparar ciertos criterios para poder generar una recomendación, por lo cual es un filtro sencillo y rápido de implementar, sin embargo, es difícil imponer una jerarquía en las recomendaciones que genera. Por otro lado, el filtro colaborativo se basa en cálculos de algoritmos para poder generar recomendaciones, lo cual lo hace un filtro casi perfecto, pero el problema radica en elegir cuál es el algoritmo adecuado para los fines, debido a que existen varios algoritmos para generar recomendaciones, y el poder controlar el inicio en frío (Cold Start) de los usuarios. Básicamente cada filtro posee sus ventajas y desventajas, pero la manera más sencilla de reducirla las desventajas y aprovechar todas sus ventajas, es utilizarlos en conjunto en un filtro híbrido, lo cual reduce sus falencias y permite generar recomendaciones mucho mejores.

Pese a que el agente no ha sido puesto a prueba con una gran cantidad de OA o una gran comunidad de usuarios con ratings, los resultados que se han registrado demuestran que efectivamente su desempeño se apega al objetivo de este proyecto, el cuál era generar un prototipo de agente que pueda recomendar recursos didácticos (OA recuperados desde un repositorio) a estudiantes basado en sus estilos de aprendizaje; además de que ha sido desarrollado de tal manera que el agente puede ser implementado en otras plataformas WEB, y a través de servicios poder comunicarse con otros agentes. Como resultado el agente puede ser empleado o mejorado a largo plazo, de tal manera que la educación tradicional de la PUCE-SI pueda empezar a orientarse hacia una instrucción personalizada mediante el uso de agentes inteligentes.

CAPÍTULO V

RECOMENDACIONES

5.1 Recomendaciones

El componente resultante de este proyecto tiene oportunidad de mejoras con respecto al algoritmo de similitud de coseno, puesto que el código desarrollado no está sujeto a un solo punto de vista ya que éste puede ser optimizado o en su defecto podría ser reemplazado por otro algoritmo que se considere más eficiente, siempre y cuando se emplee el mismo principio del uso de matrices de información generadas, ya sea a partir de un servicio o un agente externo.

Por otro lado, los filtros basados en contenido e híbrido están sujetos a los indicadores que se crean pertinentes para una recomendación, es decir, que los indicadores pueden aumentar o disminuir considerablemente, por lo cual hay que tener claros cuáles serán los indicadores claves en las recomendaciones.

Ahora bien, con lo que respecta a los indicadores del perfil de aprendizaje estos pueden cambiar, obviamente esto depende de la entidad educativa y lo que busque desarrollar en sus estudiantes, en este caso se han implementado los estilos de aprendizaje propuestos por Felder y Silverman, pero esto podría cambiar y emplearse otros estilos de aprendizaje planteados por otros autores, de manera que hay que tener una manera clara de cómo se han de obtener estos indicadores y cómo se van a representar para el agente, por lo cual se debe desarrollar un test o cuestionario idóneo para obtener esos indicadores y asignarlos a perfiles de estudiantes.

La cantidad de recomendaciones se ve comprometida al no existir un monitoreo continuo del progreso del estudiante, ya que al no tener una actualización constante de los indicadores del perfil del alumno el agente no puede generar mejores recomendaciones; por lo cual se recomienda la creación de agentes capaces de monitorear y actualizar la información que emplea el modelo.

Finalmente, se exhorta a continuar con proyectos enfocados al desarrollo de agentes inteligentes para ser empleados en el proceso de aprendizaje.

BIBLIOGRAFÍA

- Denning, P. J. (2001). *The Invisible Future: The Seamless Integration of Technology into Everyday Life*. McGraw-Hill.
- Adermann, N., & Boggiano, J. (n.d.). *Getcomposer.org*. Retrieved from <https://getcomposer.org/doc/00-intro.md>
- Adom̂ent, M., Barth, M., Fischer, D., Richter, S., & Rieckmann, M. (2014). Learning to change universities from within: A service-learning perspective on promoting sustainable consumption in higher education. *Journal of Cleaner Production*, 72–81.
- Appel, L. R., & Murphy, R. T. (1977). *Evaluation of the PLATO IV computer-based education system in the community college*. ACM SIGCUE Outlook.
- Aranda, A. D. (2012). *Moodle for distance education*. Distance Learning.
- Asoke , N., & Karmakar, A. (2014). E-Learning Methodologies, Strategies and Tools to implement lifetime education anywhere anytime. *International Journal of Innovative Research in Advanced Engineering*, 1, 194.
- Bădică, C., Zoran , B., Hans-Dieter , B., & Mirjana , I. (2011). *Software agents: Languages, tools, platforms*. (Vol. 2). Computer Science and Information Systems.
- Balabanović, M., & Shoham, Y. (1997). Fab: Content-based, collaborative recommendation. *Communications of the ACM*, 66-72.
- Biau, G., Cadre, B., & Rouvière, L. (2010). Statistical analysis of k-nearest neighbor collaborative recommendation. *The Annals of Statistics*, 1568–1592.
- Bresler, G., Chen, G. H., & Shah, D. (2014). A Latent Source Model for Online Collaborative Filtering. *NIPS*, 1-9.
- Burke, R. (2002). Retrieved from <https://pdfs.semanticscholar.org/5880/b9bc3f75f4649b8ec819c3f983a14fca9927.pdf>
- Castro, S. M., Clarenc, C. A., de Lenz, C. L., Moreno, M. E., & Tosco, N. B. (n.d.).

- Castro, S. M., Clarenc, C. A., de Lenz, C. L., Moreno, M. E., & Tosco, N. B. (2013). *ANALIZAMOS 19 PLATAFORMAS DE E-LEARNING*. Congreso Virtual Mundial de e-Learning .
- Ceibal. (2009). *Manual para el Diseño y Desarrollo de Objetos De Aprendizaje*. Uruguay.
- Collis, B. (1996). *Tele-learning in a digital world*. Londres: Thomson Computer Press.
- Django Software Foundation. (n.d.). *Djangoproject*. Retrieved from <https://www.djangoproject.com>
- Duran, D., & Arciniega, J. (2013). Algoritmo de Filtrado Híbrido-Mixto para Recomendación de Contenidos Audiovisuales a Comunidades Virtuales. *Scientia Et Technica*, 178-184.
- Felder, R. M., & Silverman, L. K. (1988). Learning and teaching styles in engineering education. *Engr. Education*, 674–681.
- García, L. (1999). Historia de la educación a distancia. (L. G. Aretio, Ed.) *Revista Iberoamericana de Educación a Distancia*, 16.
- Garrison, D. R., & Vaughan, N. D. (2007). *Blended Learning in Higher Education: Framework, Principles, and Guidelines*. John Wiley & Sons.
- Garruzzo, S., Rosaci, D., & Sarne, G. M. (2007). *ResearchGate GmbH*. Retrieved from https://www.researchgate.net/profile/Domenico_Rosaci/publication/4301011_ISABEL_A_Multi_Agent_e-Learning_System_That_Supports_Multiple_Devices/links/53e3ae4d0cf2fb74870db7a9/ISABEL-A-Multi-Agent-e-Learning-System-That-Supports-Multiple-Devices.pdf?origin=
- Guerra, A. (2013). Retrieved Noviembre 22, 2017, from <https://www.uv.mx/aguerra/documents/2013-ia2-01.pdf>
- Harsh, O., & Sohail, M. (2002). Role of Delivery, Course Design and Teacher-Student Interaction: Observations of Adult Distance Education and Traditional On-Campus Education. *International Review of Research in Open and Distance Learning*, 3.

- IRS. (2004). *IRS*. Retrieved from
<http://www.irs.gov/opportunities/procurement/article/0,,id=128685,00>.
- ITESO. (1993). *La Pedagogía Ignaciana. Un planteamiento práctico*. Roma: The International Center for Jesuit Education.
- Klašnja-Milićević, A., Vesin, B., Ivanović, M., & Budimac, Z. (2011). *E-Learning personalization based on hybrid recommendation strategy and learning style identification*. (Vol. 3). Computers & Education.
- Klašnja-Milićević, A., Vesin, B., Ivanović, M., Budimac, Z., & C. Jain, L. (2016). Recommendation Techniques for RS in E-Learning Environments—A Survey of the State-of-the-Art. In *E-Learning Systems: Intelligent Techniques for Personalization* (p. 60). Springer.
- Klašnja-Milićević, A., Vesin, B., Ivanović, M., Budimac, Z., & C. Jain, L. (2016). Adaptation of E-Learning Systems. In *E-Learning Systems Intelligent Techniques for Personalization* (p. 23). Springer.
- Llerena, N. (2016, Julio). *dspace*. Retrieved from
<http://dspace.uniandes.edu.ec/handle/123456789/4206>
- Manouselis, N., Drachsler, H., Verbert, K., & Duval, E. (2012, Marzo 23). *researchgate.net*. Retrieved from
https://www.researchgate.net/publication/234057357_Recommender_Systems_for_Learning
- Mena, B. A. (2012). *dspace*. Retrieved Mayo 11, 2017, from
<http://dspace.utpl.edu.ec/bitstream/123456789/3183/1/Tesis%20de%20Galarza%20Mena%20Bethy%20Arlene.pdf>
- Mutter, J. M. (1972, Mayo). *Calhoun*. Retrieved from
<https://calhoun.nps.edu/bitstream/handle/10945/16038/computerassisted00mutt.pdf?sequence=1>
- Paucar, M., & Alfredo, L. (2015, Octubre). DSPACE. (Riobamba, Ed.) 11. Retrieved from
<http://dspace.esPOCH.edu.ec/handle/123456789/4380>

- Penzo, W. (2009, Mayo 28). *diposit*. Retrieved from <http://diposit.ub.edu/dspace/bitstream/2445/8448/6/Elaboracion-actividades-aprendizaje-4.pdf>
- Pfleeger, S. L., & Atlee, J. M. (2010). *Software Engineering: Theory and Practice*. Prentice Hall.
- PUCE-SI. (2012, Septiembre). *PUCESI*. Retrieved from https://www.pucesi.edu.ec/phocadownloadpap/macrocurriculoinstitucionalpucesi/modelo_educativo_pucesi_v6.pdf
- Ricci, F., Rokach, L., Shapira, B., & Kantor, P. B. (2011). *Recommender Systems Handbook*. Springer. Retrieved from http://www.cs.ubbcluj.ro/~gabis/DocDiplome/SistemeDeRecomandare/Recommender_systems_handbook.pdf
- Segarra Morales, A. K. (2017). *dspace*. Retrieved from <http://dspace.utpl.edu.ec/bitstream/20.500.11962/21181/1/SEGARRA%20MORALES%20ANDREA%20KATALINA%20PROYECTO%20FINAL.pdf>
- Sierra Rodríguez, J. L., Martínez Ortiz, I., & Moreno Ger, P. (2011). *Uso de estándares aplicados a TIC en Educación*. (128-129, Trans.) Ministerio de Educación de España.
- Verdejo , F., & Gordon, D. (1998). *The Virtual Campus : Trends for higher education and training*. Chapman and Hall.
- Wiley, D. A. (2003, Septiembre). *Wesrac*. Retrieved from http://wesrac.usc.edu/wired/bldg-7_file/wiley.pdf

ANEXOS

Urkund Analysis Result

Analysed Document: TESIS Arellano Bryan.pdf (D44593626)
Submitted: 11/26/2018 11:56:00 PM
Submitted By: squishpe@pucesi.edu.ec
Significance: 5 %

Sources included in the report:

TESIS NUEVO FORMATO Arellano BG-Final.docx (D40504094)
Marco Teórico-Bryan Arellano.docx (D38663864)
<http://www.scielo.org.co/pdf/rcde/n64/n64a04.pdf>
<http://www.donsantos.com/>

Instances where selected sources appear:

11



Index of Learning Styles (ILS) Learning Style Questionnaire

This questionnaire is designed to find out what your learning preferences are. It was originally designed by Felder and Silverman at North Carolina State University, USA.

Directions

To complete the questionnaire please circle "a" or "b" to indicate your answer to every question. You may only choose one answer for each question and you must answer every question. If both "a" and "b" seem to apply to you, please choose the one that applies more frequently.

1. I understand something better after I
 - (a) try it out.
 - (b) think it through.

2. I would rather be considered
 - (a) realistic.
 - (b) innovative.

3. When I think about what I did yesterday, I am most likely to get
 - (a) a picture.
 - (b) words.

4. I tend to
 - (a) understand details of a subject but may be fuzzy about its overall structure.
 - (b) understand the overall structure but may be fuzzy about details.

5. When I am learning something new, it helps me to
 - (a) talk about it.
 - (b) think about it.

6. If I were a teacher, I would rather teach a course
 - (a) that deals with facts and real life situations.
 - (b) that deals with ideas and theories.

7. I prefer to get new information in
 - (a) pictures, diagrams, graphs, or maps.
 - (b) written directions or verbal information.

8. Once I understand
 - (a) all the parts, I understand the whole thing.
 - (b) the whole thing, I see how the parts fit.

9. In a study group working on difficult material, I am more likely to
 - (a) jump in and contribute ideas.
 - (b) sit back and listen.

10. I find it easier
 - (a) to learn facts.
 - (b) to learn concepts.

11. In a book with lots of pictures and charts, I am likely to
 - (a) look over the pictures and charts carefully.
 - (b) focus on the written text.

12. When I solve maths problems
 - (a) I usually work my way to the solutions one step at a time.
 - (b) I often just see the solutions but then have to struggle to figure out the steps to get to them.

13. In classes I have taken
 - (a) I have usually got to know many of the students.
 - (b) I have rarely got to know many of the students.

14. In reading non-fiction, I prefer
 - (a) something that teaches me new facts or tells me how to do something.
 - (b) something that gives me new ideas to think about.

15. I like teachers
 - (a) who put a lot of diagrams on the board.
 - (b) who spend a lot of time explaining.

16. When I'm analysing a story or a novel
 - (a) I think of the incidents and try to put them together to figure out the themes.

- (b) I just know what the themes are when I finish reading and then I have to go back and find the incidents that demonstrate them.
17. When I start a homework problem, I am more likely to
- (a) start working on the solution immediately.
 - (b) try to fully understand the problem first.
18. I prefer the idea of
- (a) certainty.
 - (b) theory.
19. I remember best
- (a) what I see.
 - (b) what I hear.
20. It is more important to me that an instructor
- (a) lay out the material in clear sequential steps.
 - (b) give me an overall picture and relate the material to other subjects.
21. I prefer to study
- (a) in a group.
 - (b) alone.
22. I am more likely to be considered
- (a) careful about the details of my work.
 - (b) creative about how to do my work.
23. When I get directions to a new place, I prefer
- (a) a map.
 - (b) written instructions.
24. I learn
- (a) at a fairly regular pace. If I study hard, I'll "get it."
 - (b) in fits and starts. I'll be totally confused and then suddenly it all "clicks."
25. I would rather first
- (a) try things out.
 - (b) think about how I'm going to do it.
26. When I am reading for enjoyment, I like writers to
- (a) clearly say what they mean.
 - (b) say things in creative, interesting ways.

27. When I see a diagram or sketch in class, I am most likely to remember
- (a) the picture.
 - (b) what the instructor said about it.
28. When considering a body of information, I am more likely to
- (a) focus on details and miss the big picture.
 - (b) try to understand the big picture before getting into the details.
29. I more easily remember
- (a) something I have done.
 - (b) something I have thought a lot about.
30. When I have to perform a task, I prefer to
- (a) master one way of doing it.
 - (b) come up with new ways of doing it.
31. When someone is showing me data, I prefer
- (a) charts or graphs.
 - (b) text summarizing the results.
32. When writing a paper, I am more likely to
- (a) work on (think about or write) the beginning of the paper and progress forward.
 - (b) work on (think about or write) different parts of the paper and then order them.
33. When I have to work on a group project, I first want to
- (a) have a "group brainstorming" where everyone contributes ideas.
 - (b) brainstorm individually and then come together as a group to compare ideas.
34. I consider it higher praise to call someone
- (a) sensible.
 - (b) imaginative.
35. When I meet people at a party, I am more likely to remember
- (a) what they looked like.
 - (b) what they said about themselves.
36. When I am learning a new subject, I prefer to

- (a) stay focused on that subject, learning as much about it as I can.
 - (b) try to make connections between that subject and related subjects.
37. I am more likely to be considered
- (a) outgoing.
 - (b) reserved.
38. I prefer courses that emphasise
- (a) concrete material (facts, data).
 - (b) abstract material (concepts, theories).
39. For entertainment, I would rather
- (a) watch television.
 - (b) read a book.
40. Some teachers start their lectures with an outline of what they will cover. Such outlines are
- (a) somewhat helpful to me.
 - (b) very helpful to me.
41. The idea of doing homework in groups, with one grade for the entire group,
- (a) appeals to me.
 - (b) does not appeal to me.
42. When I am doing long calculations,
- (a) I tend to repeat all my steps and check my work carefully.
 - (b) I find checking my work tiresome and have to force myself to do it.
43. I tend to picture places I have been
- (a) easily and fairly accurately.
 - (b) with difficulty and without much detail.
44. When solving problems in a group, I would be more likely to
- (a) think of the steps in the solution process.
 - (b) think of possible consequences or applications of the solution in a wide range of areas.

Now turn to the scoring sheet so you can see where your preferences are.

Learning Styles Questionnaire Scoring Sheet

1. Place a "1" in the appropriate spaces in the table below (e.g. if you answered "a" to Question 3, put a "1" in Column "a" by Question 3).
2. Add up the columns and write the totals in the indicated spaces.
3. For each of the four scales, subtract the smaller total from the larger one. Write the difference (1 to 11) and the letter (a or b) with the larger total.

Activist/Reflector			Sensing/Intuitive			Visual/Verbal			Sequential/Global		
Q	a	b	Q	a	b	Q	a	b	Q	a	b
1			2			3			4		
5			6			7			8		
9			10			11			12		
13			14			15			16		
17			18			19			20		
21			22			23			24		
25			26			27			28		
29			30			31			32		
33			34			35			36		
37			38			39			40		
41			42			43			44		
<i>Total (add up each column)</i>											
Activist/Reflector			Sensing/Intuitive			Visual/Verbal			Sequential/Global		
Q	a	b	Q	a	b	Q	a	b	Q	a	b
<i>Larger – Smaller + Letter of Larger (see below*)</i>											

**Example: If your total was 3 for a and 8 for b: 8 – 3 = 5, b is letter of larger so you would enter 5b.*

Explanation of scores

- If your score on a scale is 1-3, you have a mild preference for one or the other dimension but you are essentially well balanced.
- If your score on a scale is 5-7, you have a moderate preference for one dimension of the scale and will learn more easily in a teaching environment which favours that dimension.
- If your score on a scale is 9-11, you have a strong preference for one dimension of the scale. You may have real difficulty learning in an environment which does not support that preference.

TEST DE CALIBRACIÓN DE PERFILES (ILS MODIFICADO)

1. Entiendo mejor algo

- a) a través de imágenes, diagramas, gráficas o mapas.
- b) con instrucciones escritas.
- c) si lo practico.

2. Cuando estoy aprendiendo algo nuevo, me ayuda

- a) una imagen.
- b) palabras/texto.
- c) hablar de ello.

3. En un libro con muchas imágenes y gráficas es más probable que

- a) revise cuidadosamente las imágenes y las gráficas.
- b) me concentre en el texto escrito.
- c) comience a trabajar en su solución inmediatamente.

4. Recuerdo mejor

- a) lo que veo.
- b) lo que oigo.
- c) algo que he hecho.

5. Para divertirme, prefiero

- a) ver televisión.
- b) leer un libro.
- c) hacer algo y ver qué sucede.

6. Cuando alguien me enseña datos, prefiero

- a) gráficas.
- b) resúmenes con texto.
- c) participe y contribuya con ideas.

7. Me gustan los maestros

- a) que utilizan muchos esquemas en el pizarrón.
- b) que toman mucho tiempo para explicar.
- c) realizan una "tormenta de ideas" donde cada uno contribuye con ideas.

8. Cuando veo un esquema o bosquejo en clase, es más probable que recuerde

- a) la imagen.
- b) lo que el profesor dijo acerca de ella.
- c) cómo resolvimos el esquema o bosquejo.