

**SISTEMA DE RECOMENDACIONES CONSCIENTE DEL
CONTEXTO COMO APOYO A PROGRAMAS DE PROMOCIÓN
DE ACTIVIDAD FÍSICA**



Gineth Magaly Cerón Ríos

**Universidad del Cauca
Facultad de Ingeniería Electrónica y Telecomunicaciones
Departamento de Telemática
Línea de Investigación en e-Salud
Diciembre de 2020
Popayán**

**SISTEMA DE RECOMENDACIONES CONSCIENTE DEL
CONTEXTO COMO APOYO A PROGRAMAS DE PROMOCIÓN DE
ACTIVIDAD FISICA**

Tesis de doctorado en Telemática



Gineth Magaly Cerón Ríos

Director: PhD. Ing. Diego Mauricio López

**Universidad del Cauca
Facultad de Ingeniería Electrónica y Telecomunicaciones
Departamento de Telemática
Línea de Investigación en e-Salud
Diciembre 2020
Popayán**



Agradecimientos

En primer lugar, deseo expresar mi agradecimiento a Dios porque es quien me ha ayudado y me ha dado fuerza, sabiduría y dirección en cada paso de mi vida.

También mis más sinceros agradecimientos a mi director de tesis doctoral, Dr. Diego Mauricio López, por la dedicación y apoyo que me ha brindado, por el respeto a mis sugerencias e ideas y por la dirección y la gran persona que es, porque ha facilitado la comunicación y el trabajo. Gracias por la confianza que deposito en mí.

Zuiero agradecer a todos las personas que han hecho posible este logro con su afecto, cariño y amor. Gracias a ellos tuve la fuerza y la motivación que anima a crecer como persona y como profesional. Gracias a mi familia, a mis padres y a mi hermano, y demás familiares.

Gracias a mis amigos, por su apoyo espiritual y emocional, necesarios en los momentos difíciles de este trabajo y esta profesión. Gracias por su paciencia, comprensión y solidaridad con este proyecto.

Asimismo, agradezco al departamento nacional de ciencias de Colombia denominado Colciencias y Colfuturo antes que financiaron todo este proceso de aprendizaje y nuevo conocimiento alcanzado en este doctorado.

Un trabajo de investigación es siempre fruto de grandes alianzas, ideas, proyectos y esfuerzos entre diferentes grupos de investigación, por eso agradezco al grupo de investigación G17 (Grupo de ingeniería telemática) del departamento de Telemática de la Universidad del Cauca y el grupo G1A de Inteligencia artificial de la universidad Complutense de Madrid. Mis más sinceros agradecimientos, a los investigadores de cada uno de estos grupos que fueron de gran apoyo con su experiencia y conocimiento, su tiempo, orientación y atención a mis consultas sobre diferentes temas relacionados con esta tesis.

Gracias a todos, Dios les bendiga.



Abstract

Recommender systems (RS) are useful tools for filtering and sorting items and information for users. There is a wide diversity of approaches that help creating personalized recommendations. Context-aware recommender systems (CARS) are a kind of RS which provide adaptation capabilities to the user's environment, e.g., by sensing data through wearable devices or other biomedical sensors. In healthcare and wellbeing, CARS can support health promotion and health education, considering that each individual requires tailored intervention programs. Our research aims at proposing a context-aware mobile recommender system for the promotion of healthy habits. The system is adapted to the user's needs, his/her health information, interests, time, location and lifestyles. In this paper, the CARS computational architecture and the user and context models of health promotion are presented, which were used to implement and test a prototype recommender system.

Context-aware recommender systems (CARS) are a kind of recommender system that adapts to the current circumstances of the user, providing accurate recommendations about different products, services and/or resources. Contextual information can be obtained from online resources, services, stationary or mobile devices, or wearable sensors. CARS address the fact that users interact with the system within a particular "context", and when the context changes, the preferences may also vary. CARS have huge potential for supporting health promotion programs, e.g., by recommending educational multimedia resources. Examples of CARS are Mopet, Fittle and Empower; they are mobile applications that make recommendations for stretching exercises and strengthening outdoor activities, based on user's information. Diabeticlink is a mobile application, which recommends videos and articles about exercise and healthy diabetic diet, based on user data and his/her interaction with the system. It refers to other data collected through sensors, and interrelates user's life styles and risk factors.

This Thesis proposes a recommender system as well as user and context models for health promotion CARS. Based on the proposed architecture, we implemented the context aware recommender system CoCARE, able to recommend appropriated multimedia resources on physical activity (PA) and healthy diet (HD).



Tabla de Contenidos

1.	Introducción	10
1.1.	Escenario de Motivación	11
1.2.	Planteamiento del Problema	13
1.3.	Objetivos.....	16
1.3.1.	Objetivo General	16
1.3.2.	Objetivos específicos	16
1.4.	Metodología.....	17
1.5.	Contenido de Monografía	17
1.6.	Estado Actual del Conocimiento	18
1.6.1.	Contexto de la investigación.....	18
1.6.2.	Metodología de la revisión.....	20
1.6.3.	Trabajos relacionados	26
1.6.3.1.	Sistemas de Recomendaciones.....	26
1.6.3.2.	Sistemas de Recomendaciones Conscientes del Contexto	27
1.6.3.3.	Sistemas de Recomendaciones en Salud.....	28
1.7.	Brechas	30
1.8.	Contribuciones.....	31
1.8.1.	Ontología OntoCOCARE.....	31
1.8.2.	Algoritmos para la predicción de preferencias de usuarios usando contexto 31	
1.8.3.	Implementation de CoCARE	31
1.8.4.	Publicaciones	31
1.9.	Conclusiones Capitulo 1	32
2.	Capítulo 2. Modelado de Usuario Consciente del Contexto	33
2.1.1.	Introducción Capitulo 2.....	33
2.1.2.	Definiciones	34
2.1.3.	Modelado de Usuario Consciente del Contexto.....	34
2.1.4.	Representación formal del modelo de datos de usuario basado en contexto 38	
2.1.5.	Sistemas de recomendaciones basados en ontologías.....	39
2.1.6.	Tipos de ontologías y criterios de clasificación	41
2.1.7.	Metodología para crear la ontología:	43
2.1.8.	Selección de Ontologías	45
2.1.9.	Criterios de selección de ontologías.....	49
2.1.10.	Ontología de Alto Nivel BFO	50
2.1.11.	Ontología SNOMED (Core)	53
2.1.12.	Ontología PACO (Dominio)	54
2.1.13.	ReCONTO Ontología Contextual	54



2.1.14.	OntoCOCARE Ontología para el sistema de recomendación contextual en el dominio de salud	55
2.1.15.	Clases de la ontología OntoCOCARE	55
2.1.16.	Data Properties	59
2.1.17.	Object Property	60
2.1.18.	Discusión Capitulo 2.....	62
2.1.19.	Conclusión Capitulo 2	65
3.	Capítulo 3. Construcción de un sistema de Recomendaciones consciente del contexto para promoción de Actividad Física CoCARE.....	67
3.1.1.	Introducción Capitulo 3.....	67
3.1.2.	Sistemas de recomendaciones	69
3.1.3.	Clásicos Vs Contextuales.....	69
3.1.4.	Técnicas de recomendaciones.....	70
3.1.9.	Adaptación de técnicas de recomendación para la inclusión de contexto ..	77
3.1.1.	Métricas de similaridad.....	79
3.1.2.	Métricas de evaluación.....	81
3.1.3.	Implementación del sistema de recomendaciones contextual Cocare	82
3.1.4.	Arquitectura Cocare	82
3.1.5.	Descripción CoCARE	84
3.1.5.1.	Diseño CoCARE	85
3.1.1.	Funciones de CoCARE	89
3.1.2.	Algoritmo Híbrido CoCARE	96
3.1.3.	Discusión Capitulo 3.....	99
3.1.4.	Conclusión Capitulo 3	100
4.	Análisis de resultados	101
4.1.	Introducción capítulo 4.....	101
4.2.	Definición de recomendadores y medidas de similitud a evaluar	102
4.2.1.	SisRec 1. Basado en conocimiento sin contexto	105
4.2.1.	SisRec 2. Basado en contenidos sin contexto	107
4.2.2.	CARS 1. Consciente del contexto	108
4.2.3.	CARS 2. Híbrido contextual.....	109
4.3.	Pruebas offline RS clásicos Vs Contextuales.....	110
4.3.1.	Plan de pruebas offline RS clásicos Vs Contextuales	110
4.3.2.	Resultados de pruebas offline RS clásicos Vs Contextuales	112
4.3.2.1.	Resultados Métrica Precisión	113
4.3.2.1.	Resultados Métrica Recall	115
4.3.2.1.	Resultados Métrica F1 score	117
4.4.	Pruebas Online experiencia de usuario y satisfacción	119
4.4.1.	Resultados Pruebas Online.....	119
4.4.2.	Dsicusión Capitulo 4.....	121



4.5.....	Conclusiones Capitulo 4
122	
5. Conclusiones y Trabajos futuros	124
5.1. Conclusiones	124
5.2. Trabajos futuros.....	126
6. Referencias	127
Anexos.....	126



Lista de tablas

Tabla 1. Relación estado del arte.....	22
Tabla 2. Publicaciones.....	31
Tabla 3. Clasificación de datos contextuales.	37
Tabla 4. Caracterización del modelo de usuario.	38
Tabla 5. Lista de Ontologías Pre-seleccionadas	45
Tabla 6. Matriz de factorización	77
Tabla 7. Kn a recomendar basado en contenido.....	103
Tabla 8. Kn a recomendar basado en conocimiento	103
Tabla 9. Datos de data set para el recomendador de conocimiento	106
Tabla 10. Datos de dataset de items.....	107
Tabla 11. Comparativa de Precisión	111
Tabla 12. Comparativa de Recall	112
Tabla 13. Comparativa de F1 Score	112
Tabla 16. Características evaluadas	120



Lista de figuras

Figura 1. Escenario de Motivación	11
Figura 2. Metodología	17
Figura 3. Modelo Contextual incluyendo dominio de la salud	35
Figura 4. Método de adaptación.....	35
Figura 5. Clasificación de las ontologías oberle	42
Figura 6. Tipo de Ontologías según el grado de especificidad	43
Figura 7. Metodología OdontoAdapt [120]	45
Figura 8. Entidad continuants BFO	52
Figura 9. Entidad Ocurrents BFO.....	53
Figura 10. Ontología SNOMED [136]	54
Figura 11. Clases principales OntoCocare	56
Figura 12. Relaciones con los datos del recomendador.....	57
Figura 13. Clases Contextual_information	57
Figura 14. Clases Item_information	58
Figura 15. Clases de User_information	59
Figura 16. Propiedades de los datos.....	59
Figura 17. Taxonomía de relaciones	61
Figura 18. Relaciones ontologicas	61
Figura 19. Diagrama general Cocare	68
Figura 20. Diseño paralelo de un recomendador hibrido	75
Figura 21. Diseño secuencial del recomendador hibrido.....	75
Figura 22. Clasificación de sistemas híbridos y sus técnicas	76
Figura 23. Matriz de factorización contextual	78
Figura 24. Técnicas de Reducción de matriz de factorización contextual.....	79
Figura 25. Arqutectura de CoCARE	83
Figura 26. Logo CoCARE en forma de cuadrado	86
Figura 27. Logo CoCARE en forma rectangular	86
Figura 28. Sistema de Recomendaciones consciente del context CoCARE.	86
Figura 29. Relación de datos del Sistema	88
Figura 30. Secuencia de privilegios en el uso del Sistema CoCARE.	89
Figura 31. Casos de Uso Experto en salud	90
Figura 32. Casos de uso administrador.....	90
Figura 33. Casos de Uso Invitado	91
Figura 34. Casos de Uso Usuario	91
Figura 37. Registrar datos adicionales	92
Figura 39. Vista de subir video.....	93
Figura 35. Ver recomendación	93
Figura 40. Buscador de videos por categoria	94



Figura 41. Chatbot	95
Figura 42. Historial CoCARE	95
Figura 36. Calificar Video.....	96
Figura 43. Combinación de estrategias de recomendación híbrida	97
Figura 44. Proceso de recomendador híbrido CoCARE	99
Figura 45. Esquema de pruebas offline de recomendadores	104
Figura 46. Proceso de prueba de los sistemas de recomendaciones clásicos.	105
Figura 47. Proceso de prueba de los sistemas de recomendaciones contextuales ...	105
Figura 48. Comparativa de Precisión recomendador basado en contenido.....	113
Figura 49. Comparativa de Precisión recomendador basado en conocimiento.	114
Figura 50. Comparativa de Precisión recomendador basado en contexto.....	114
Figura 51. Comparativa de Recall recomendador basado en contenido.	115
Figura 52. Comparativa de Recall recomendador basado en conocimiento.	116
Figura 53. Comparativa de Recall recomendador basado en contexto.	116
Figura 54. Comparativa de F1 Score recomendador basado en contenido.....	117
Figura 55. Comparativa de F1 Score recomendador basado en conocimiento.	118
Figura 56. Comparativa de F1 Score recomendador basado en contexto.....	118



1. Introducción

La organización Mundial de la Salud (OMS) indica que uno de los grupos de enfermedades no transmisibles (ENT) más prevalentes en el mundo son las enfermedades cardiovasculares que provocan aproximadamente 17.3 millones de muertes por año, seguidas por el Cáncer, las enfermedades respiratorias y la diabetes [1] Una de las estrategias más efectivas para disminuir los factores de riesgo y prevenir ENT es la promoción de hábitos y estilos de vida saludables¹. Algunos autores han demostrado que se logra evidenciar cambios en los hábitos de las personas si se promueve la actividad física y/o la sana nutrición, como pilares en el proceso de salud [2].

Actualmente las tecnologías de la información y las comunicaciones están influyendo positivamente en la salud de las personas[3], apoyando procesos de promoción de hábitos saludables, uno de los medios más usados es la Internet y específicamente los contenidos multimedia. Sin embargo, debido a la gran cantidad de contenidos multimedia disponibles en la nube relacionados con salud, para los usuarios es muy difícil descubrir los adecuados para su bienestar, provocando frustración y desanimo.

La forma como una persona reacciona frente a esta problemática depende en gran medida de sus objetivos, gustos y preferencias, pues de antemano existe una predisposición a aceptar ciertos contenidos y a rechazar otros. Ya sea porque está influenciado por otras personas que logran cambiar su perspectiva, o el ambiente en el que se encuentra que pueden influir y hacer que alguien acepte cosas que normalmente rechazaría o por el contrario rechace cosas que normalmente aceptaría[4][5][6].

Lo anterior permite comprender que la promoción de hábitos saludables a través de contenidos multimedia puede ser más efectiva en la medida en que se entregue al usuario un contenido adecuado para su condición de salud, en el lugar que se encuentre y en el momento preciso, y este momento y lugar vienen acompañado no solo de una fecha y una localización, sino de un conjunto de variables que suelen conocerse como contexto. De esta forma, considerar la información de contexto se convierte en un elemento relevante en el momento de pensar en recomendarle

¹ "la percepción que un individuo tiene de su lugar en la existencia, en el contexto de la cultura y del sistema de valores en los que vive y en relación con sus objetivos, sus expectativas, sus normas, sus inquietudes". [4]

actividad física a un usuario, y es por este motivo que este trabajo se enfoca en la construcción de un sistema de recomendaciones para promoción de actividad física que involucra información contextual. Para ello, se definirán el conjunto de variables que serán consideradas como contexto, el o los mecanismos para incluirlas en el sistema y las herramientas para su implementación y evaluación.

A lo largo de este documento se describe la construcción del sistema a partir del análisis de la literatura existente, pasando por el diseño software y terminando con pruebas del sistema.

1.1. Escenario de Motivación

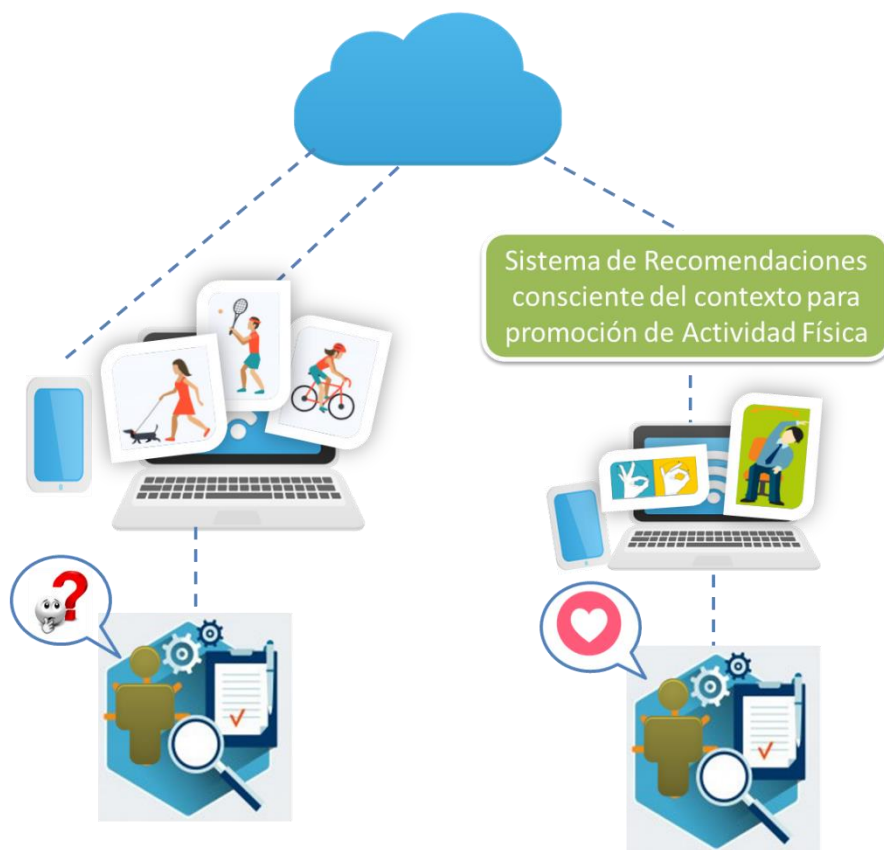


Figura 1. Escenario de Motivación

(Fuente:elaboración propia)

Existe una necesidad inminente de cuidar la salud de las personas y mejorar su calidad de vida. Es por esa razón que muchas personas acuden a Internet en



busca de recomendaciones para ello, encontrando un gran número de contenidos multimedia (video, imágenes, texto) relacionados con el cuidado de la salud. Sin embargo, un gran porcentaje de estos contenidos no son adecuados para la persona. Por ejemplo, considérese la siguiente situación. Una persona adulta entre los 25 y 30 años de edad, con sobrepeso y problemas cardiacos desea bajar de peso, se encuentra en su trabajo y tiene 15 minutos disponibles para realizar algún tipo de actividad. El usuario ingresa a Internet a un buscador de contenidos multimedia conocido 'Google' y escribe su deseo "Bajar de Peso", el buscador le arrojó más de 1000 recomendaciones entre videos, imágenes, documentos, etc...el individuo selecciona un video que dura aproximadamente 1 hora, es relacionado con actividad física para realizar al aire libre y con una mascota, el usuario descarta esa opción y selecciona otra, pero tampoco satisface su necesidad; después de más de 5 minutos de búsqueda, encuentra un contenido que le gusta y es adecuado para el lugar, pero supera el tiempo del que dispone, sin embargo lo inicia, pero no lo puede terminar, por otro lado siente que esa actividad no fue tan benéfica para su condición cardiaca. Esta situación se repite una y otra vez lo que hace que este individuo pierda el interés por buscar alternativas para mejorar su salud.

El escenario anterior motiva a la construcción de un sistema que incluya lo necesario para mejorar la experiencia del usuario al buscar recomendaciones de hábitos saludables, específicamente actividad física. Ya que algunos contenidos multimedia benéficos para él podrían ser rechazados, y aceptar otros contenidos que desea y resuelve una necesidad en el momento, pero no favorables para su condición de salud. Adicionalmente, un sistema de recomendaciones de actividad física podría ayudar a mejorar la adherencia de los usuarios a programas de promoción y prevención de salud de manera que él no termine abrumando con demasiadas cosas, algunas buenas y otras no, pero al final, tantas que para el usuario es una pérdida de tiempo revisar cada una y termina rechazando todo.

La Figura 1 resume este problema, de ahí surge la motivación de este trabajo de grado, que es desarrollar un Sistema de recomendaciones basado en contexto para el dominio de la salud que consiga información del usuario y su contexto. Con base en reglas pre establecidas, recomiende contenidos multimedia de actividad física, previamente seleccionado con ayuda de expertos en salud. Las recomendaciones deben ser adecuadas y precisas con base en la condición de salud del usuario, preferencias y variables del entorno.



1.2. Planteamiento del Problema

En esta sesión se define el problema y la pregunta de investigación que se desarrolló en esta tesis de Doctorado, además el estado del arte, los objetivos y contribuciones planteadas.

A nivel mundial y nacional se vienen incrementado las tasas de morbi-mortalidad por enfermedades no transmisibles (ENT), entre las cuales se encuentran la obesidad, enfermedades cardiovasculares, hipertensión arterial, diabetes tipo II y enfermedades respiratorias. La organización Mundial de la Salud (OMS) indica que uno de los grupos de enfermedades crónicas más prevalentes en el mundo son las enfermedades cardiovasculares que provocan aproximadamente 17.3 millones de muertes por año, seguidas por el Cáncer con 7.6 millones de defunciones, las enfermedades respiratorias con 4.2 millones y la diabetes con 1.3 millones de muertes al año[1].

Una de las estrategias más efectivas para disminuir los factores de riesgo y prevenir ENT es la promoción de hábitos y estilos de vida saludables². Los hábitos y estilos de vida saludables abarcan diferentes líneas de intervención como el autocuidado, la actividad física, la nutrición sana, la educación en salud y el buen manejo del tiempo libre. Algunos autores han demostrado que se logra evidenciar cambios en los hábitos de las personas si se promueve la actividad física y/o la nutrición sana, como pilares en el proceso de salud[7].

En la literatura se han encontrado varios artículos relacionados con el uso de las Tecnologías de la Información y las Comunicaciones (TIC) en la promoción de hábitos y estilos de vida saludables. Uno de ellos es el trabajo de Robinson Bannink publicado en 1989[8], el cual es considerado por algunos autores como uno de los primeros trabajos en esta área. Este estudio se realizó con jóvenes universitarios usando la plataforma Salud-Net, una red informática para promoción de la salud, que enfatiza en el auto-cuidado y estrategias preventivas. Sin embargo, fue solo hasta el año 2005 con el trabajo de Sloomaker [9] que el área de salud a través de la Internet empieza a tomar importancia, mediante una plataforma que promociona actividad física basada en el género y edad del usuario. Es así como empiezan a desarrollarse distintas intervenciones TIC como apoyo a la promoción de hábitos y

² "la percepción que un individuo tiene de su lugar en la existencia, en el contexto de la cultura y del sistema de valores en los que vive y en relación con sus objetivos, sus expectativas, sus normas, sus inquietudes". [4]



estilos de vida saludables adaptables a las necesidades y perfil de los usuarios. No obstante, las propuestas seguían siendo solo pequeños estudios experimentales principalmente sobre la Web.

En el año 2007 se incorpora el concepto de las tecnologías móviles a la promoción de la salud y prevención de enfermedades. Uno ejemplo de los primeros proyectos es una clínica portable (móvil) adecuada con instrumentos y equipos médicos para educación y prevención del asma[10]. Posteriormente, surgieron nuevas intervenciones que usan no solo la Web, sino también teléfonos celulares, GPS (Wiehe SE1, 2008), Kinect[11], Televisión Inteligente, entre otros; además empiezan a realizarse estudios más formales del impacto de las intervenciones TIC en la salud de las personas, cambio de comportamiento, experiencia (satisfacción) del usuario, etc.[12], [13].

Hoy día la cantidad de contenidos multimedia en Internet es grande, causando desbordamiento de Información y dificultado la navegación en diversos hiperespacios; lo que se está convirtiendo en un problema para ofrecer a los usuarios contenido de calidad y que satisfaga sus necesidades [14], [15]. Particularmente, la cantidad de información en Internet sobre salud aumenta día a día, en especial la información compartida en medios electrónicos de comunicación social (social media) como redes sociales, foros, twitter, whatsapp, etc. Sin embargo, la información en salud compartida en Internet no es ampliamente usada por los profesionales de la salud en su práctica médica, principalmente debido a sus limitaciones en calidad[16]. En el área de la promoción de la actividad física, existen ejemplos de intervenciones soportadas en TIC[11], [17] que utilizan videos, audios, o juegos serios con contenidos multimedia. Una de las características más notorias de estos contenidos multimedia es que la mayoría son contenidos propios y no abiertos, pues han sido generados para cada proyecto en particular.

Entendiendo la promoción de actividad física como una forma de prevenir futuras enfermedades crónicas en los usuarios a través de recomendaciones saludables que el usuario deberá poner en práctica en su vida normal y de manera continua, la gran cantidad de Información (contenidos) multimedia disponible en Internet, se considera como una oportunidad para ofrecer al usuario recomendaciones para promover hábitos y estilos de vida saludables (audio, video y datos). Un inconveniente para usar esta información en intervenciones es la poca calidad de estos contenidos[18], sin embargo Fernandez-Luque demuestra que es posible encontrar contenido de calidad en Youtube, utilizando sistemas automáticos de búsqueda y recuperación de información en la Internet[19]. No obstante, este contenido no es adaptado a las preferencias y perfil de los usuarios.



De la misma manera, para incrementar el uso de información en Internet que ofrezca recomendaciones sobre actividad física es importante considerar que cada persona cuenta con diferentes características y contexto (edad, peso, talla, ocupación, lugar de trabajo, cultura, amigos, hábitos, discapacidades etc.), además diferentes necesidades (subir de peso o bajar de peso, eliminar sedentarismo, etc.)[20]. Más aún, de acuerdo con el estado del arte presentado en la siguiente sección, las actuales intervenciones TIC son diseñadas en su mayoría para personas con conocimientos tecnológicos básicos y sin discapacidades (motoras, visuales o auditivas), dejando a un lado un gran grupo de personas que también necesitan mejorar su calidad de vida. En conclusión, los usuarios necesitan sistemas que se adapten a sus necesidades, características y tecnologías, recomendándole actividad física con base en sus intereses y necesidades.

Una gran parte de las investigaciones muestran los RS como una de las posibles soluciones a los problemas anteriormente mencionados, siendo una herramienta útil para proveer recomendaciones personalizadas sobre hábitos y estilos de vida saludable[21]. No obstante, los RS con enfoque de filtrado colaborativo o basados en contenido o híbridas típicamente solo consideran 2 dimensiones como son el usuario y el ítem[22]. En la salud como se mencionó anteriormente, la OMS sugiere incorporar el término de contexto dentro de la promoción de hábitos saludables lo cual requiere involucrar otro tipo de parámetros que hacen complejo el análisis de la información para generar una recomendación adecuada. Existen desarrollos en Sistemas de Recomendación basados en contexto (CARS), ej.[23], pero en salud los parámetros contextuales deben ser definidos de acuerdo a las condiciones médicas, disponibilidad de TIC, el acceso voluntario a sus datos además del uso de dispositivos no invasivos. Actualmente los CARS puede abarcar técnicas de filtrado colaborativo y basado en contenido, sin embargo algunos autores recomiendan[23], [24] usar un enfoque como el basado en conocimiento ya que se hace un modelado previo de las características de usuario y su contexto, ayudando a hacer más precisa la recomendación. Estos sistemas no han sido propuestos aún en el área de promoción y prevención de hábitos y estilos de vida saludable[25].

Se concluye que en área de salud es importante considerar tanto los contenidos y sus metadatos, así como el conocimiento del usuario y su contexto el cual es principalmente determinado por profesionales de la salud de acuerdo a las condiciones de cada individuo, por lo tanto, el enfoque que mejor se asocia a este tipo de sistemas de recomendaciones es el híbrido. En un enfoque de RS híbrido para promoción de actividad física, debe elegirse que técnica y/o algoritmos serían



los más adecuados para las recomendaciones, ya que hasta el momento no se cuenta con un estudio o investigación que proporcione esta información.

De lo expuesto anteriormente, se plantea la siguiente pregunta para orientar el proceso de investigación del presente trabajo:

¿Cómo recomendar de manera automática y personalizada contenidos multimedia disponibles en Internet, que favorezcan la promoción de la actividad física?

Como hipótesis, se plantea diseñar e implementar un sistema de recomendaciones consciente en el contexto que favorezca la promoción de actividad física, que considere las necesidades, características y contexto del usuario, además de los contenidos multimedia disponibles en Internet.

1.3. Objetivos

1.3.1. Objetivo General

Proponer un sistema de recomendaciones consciente en el contexto como apoyo a programas de promoción de actividad física.

1.3.2. Objetivos específicos

- 1.3.2.1. Construir un modelo de usuario consciente del contexto para promoción de actividad física que integre las dimensiones de usuario, contenido y contexto.
- 1.3.2.2. Evaluar y seleccionar un (unos) algoritmo(s) con enfoque híbrido para generar recomendaciones dirigidas a las características individuales y de contexto de cada usuario.
- 1.3.2.3. Integrar el(los) algoritmo(s) seleccionados y el modelo de usuario consciente del contexto para promoción de actividad física y evaluar la precisión y satisfacción de usuario de las recomendaciones proveídas por el sistema.

1.4. Metodología

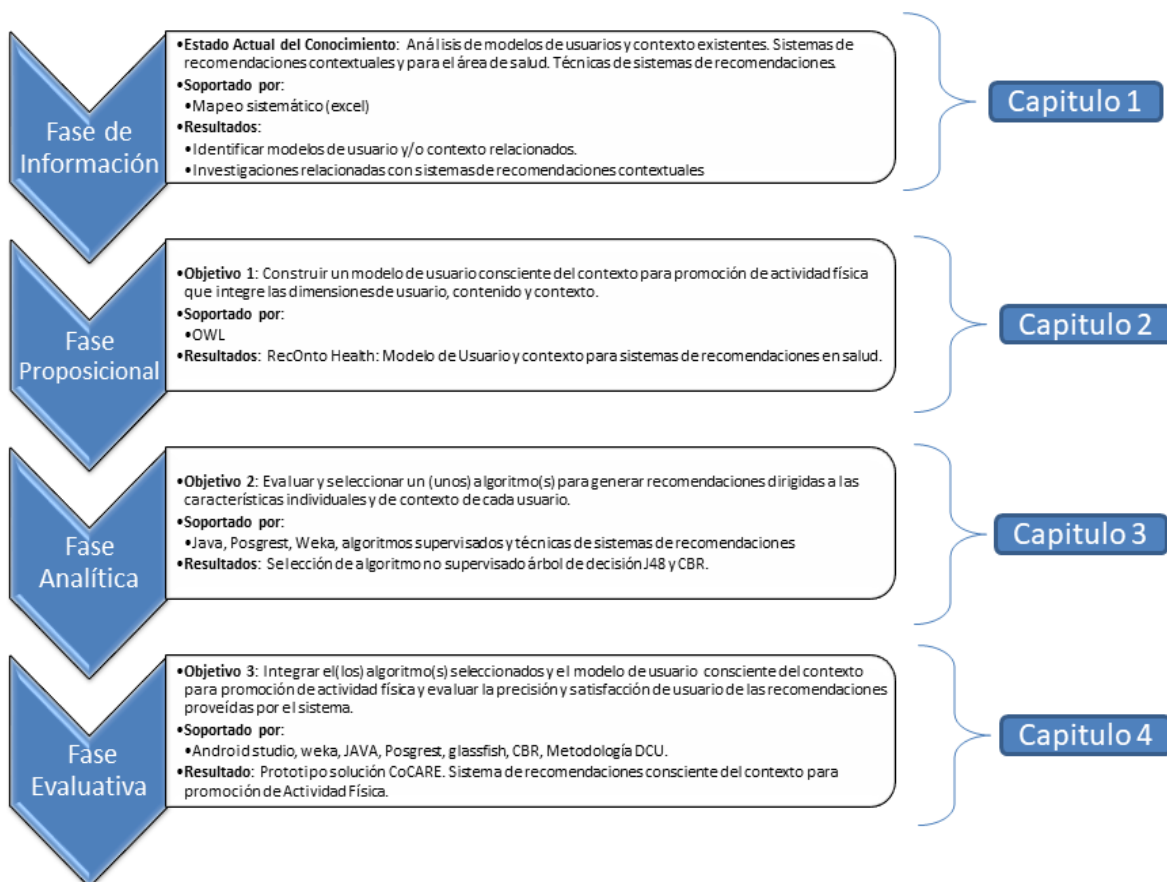


Figura 2. Metodología

(Fuente: elaboración propia)

1.5. Contenido de Monografía

Capítulo 1. Introducción

Definición del problema y la estructura general del desarrollo del proyecto de investigación, y el estado actual del conocimiento donde presenta los trabajos relacionados al proyecto, se divide en tres grupos temáticos: sistemas de recomendaciones, sistemas de recomendaciones basados en contexto y sistemas de recomendación para salud. Al final se presentan las brechas más importantes que se encontraron.



Capítulo 2. Ontología OntoCOCARE

En este capítulo se describe la ontología propuesta en esta tesis para modelar los datos del usuario y su contexto para el dominio de salud específicamente en actividad física y se construyen todas las relaciones que soportaran la integración de dichas variables dentro de un sistema de recomendaciones.

Capítulo 3. Construcción de un sistema de recomendaciones consciente del contexto para apoyo de la promoción de actividad física.

A partir de la ontología planteada en el capítulo 2, se diseña una arquitectura de referencia que permita la implementación del sistema de recomendaciones contextual.

Capítulo 4. Pruebas y resultados

Presenta el plan de pruebas diseñado para determinar el comportamiento del sistema de recomendaciones al usar información contextual. Inicialmente se harán pruebas de escritorio (offline) de los algoritmos y ecuaciones y posteriormente se prueba el prototipo funcional CoCARE con usuarios (Online) que puedan interactuar con el sistema. Al final del capítulo se presentan los resultados obtenidos.

Capítulo 5. Conclusiones y trabajo futuro

Por último, se analizan los resultados del trabajo realizado, se detallan las principales contribuciones obtenidas durante el ciclo del proyecto y se expone un conjunto de recomendaciones importantes para el desarrollo de trabajos futuros.

1.6. Estado Actual del Conocimiento

1.6.1. Contexto de la investigación

A nivel mundial y nacional se ha visto un incremento en las tasas de morbi-mortalidad por enfermedades no transmisibles, ENT, entre las cuales se encuentran la obesidad, enfermedades cardiovasculares, hipertensión arterial, diabetes tipo II y enfermedades respiratorias, entre otras.

Es conocido en el ámbito de la salud y la economía, que los procedimientos preventivos tienen beneficios muy elevados, encontrándose que disminuyen los costos de atención y especialmente los costos por discapacidad generados por ECNT y su inversión es relativamente baja en comparación con los costos generados por atención en caso de enfermedad.

Lo anterior indica que es necesario y urgente, invertir en la promoción de los hábitos y estilos de vida saludables como una alternativa de prevención de ENT como parte integral del desarrollo socioeconómico sostenible.





La anterior situación es factible de modificarse a través de un proceso educativo que promueva por lo menos la actividad física. Se ha hecho tan relevante la prevención de enfermedades no transmisibles que muchos avances tecnológicos y novedosos han surgido para dar soporte a esta necesidad.

Considerando los beneficios que trae a la salud de las personas el uso de las TIC en la prevención de enfermedades, es necesario un esfuerzo por mejorar la forma como los usuarios reciben los contenidos de promoción de hábitos saludables específicamente actividad física. De esta forma, algunos proyectos se han enfocado en cumplir este objetivo mediante la utilización de sistemas de recomendaciones, y algunos sistemas conscientes del contexto. De esta manera, se generan ambientes de interacción que pueden alimentar y mejorar la forma como los usuarios reciben y consumen contenidos de actividad física adaptados a sus necesidades e intereses.

Ahora bien, aunque este tipo de sistemas pueden suplir un poco este problema, no es suficiente en la promoción de actividad física considerar solo las pocas variables que un sistema de recomendaciones clásico considera, es decir, no es suficiente con considerar solo los usuarios y los ítems. Una razón es porque la actividad física depende principalmente del momento y lugar es decir que es situacional, tanto que la OMS [7] afirma que depende mucho del entorno o como es llamado, del contexto, pues no es lo mismo recomendar un contenido en lugares abiertos que en lugares cerrados. O cuando está lloviendo, incluso en [21] se indica que no considerar variables como la posición del usuario para un sistema de actividad física genera un problema un problema de deserción a los programas de promoción de actividad física. Es por este motivo, que este trabajo se enfoca en el diseño y construcción de un sistema de recomendaciones que involucre información contextual. Para ello, se investigará sobre las posibles variables que deben considerarse como contexto en el dominio de salud, las principales características de los sistemas de recomendaciones, los mecanismos o aproximaciones para incluir las variables de contexto definidas dentro del cálculo de recomendaciones y las herramientas para la implementación.

En la sección siguiente, se describe brevemente la metodología utilizada para el desarrollo del trabajo de grado, donde se incluye construcción el estado actual del conocimiento relacionado con esta investigación, el diseño software y las pruebas.



1.6.2. Metodología de la revisión

Para alcanzar el objetivo propuesto, se utilizó la metodología de mapeo sistemático. Es un método para construir clasificaciones y obtener información sobre el conocimiento existente en una temática específica, identificando vacíos, necesidades y brechas en un área determinada. El análisis de los resultados se realiza categorizando los hallazgos y contando la frecuencia de publicaciones dentro de cada categoría para determinar la cobertura de las distintas áreas de un tema de investigación específico [26].

El mapeo se realizó siguiendo las etapas propuestas por Peterson [27] que define 5 etapas: A) Definir preguntas de investigación, B) Realizar la búsqueda literaria, C) Seleccionar estudios, D) Clasificar artículos y E) Extraer y realizar la agregación de datos.

Se plantearon varias preguntas que se buscó resolver con el mapeo:

- ¿Cuáles artículos son de tipo de descriptivo o evaluativos?
- ¿En cuales áreas se han venido usando los sistemas de recomendaciones?
- ¿En el área de salud, en que línea de intervención han trabajado?
- ¿usan modelado de datos y que tipo de modelado?
- ¿Qué técnicas de Inteligencia Artificial usan?
- ¿Qué tipo de técnicas de adaptación hipermedia usan?

Para la consulta literaria se realizó en las bases de datos google scholar, ACM y Pubmed. La cadena de búsqueda se dividió en 6 puntos fundamentales y sus sinónimos:

- Programas de bienestar o vivir bien.
- Promoción y prevención de la salud.
- Hábitos y estilos de vida.
- Sistemas de recomendaciones y sus técnicas.
- Sistemas de recomendaciones contextuales.
- Sistemas de recomendaciones en salud.

La búsqueda se limitó a artículos de publicaciones académicas, que mostraran texto completo entre los años 2012 a 2019. En la primera búsqueda se encontró un total de 150 artículos potencialmente útiles, pero al aplicar los criterios de



tipificación establecidos en esta tesis finalmente 56 cumplieron la mayoría de criterios en la segunda revisión y la última revisión se seleccionaron 42 que se describen en la Tabla 1. Los criterios de tipificación fueron: publicaciones arbitradas, journals, full text y que dieran respuesta a más de 3 de las 6 preguntas. Con esto se da por concluido el estado actual del conocimiento revisado, la Tabla 1 resume las brechas encontradas a partir de esta revisión.

Tabla 1. Relación estado del arte

Referencia	Tipo de investigación			Dominio	Línea de Intervención/salud			Tipo de Modelado	Técnica de IA para Componente de Adaptación										Técnica de Adaptación Hipermedia																				
																			Contenido			Presentación			Navegación														
	Teórica	Descriptiva	empírica		Evaluación Software	Educación	Salud		Otro	Actividad física	Dieta Saludable	Autocuidado	Usuario /modelado de datos	Contexto	CBR	clustering	Árboles de decisiones	Naive/Bayes	Redes Bavesianas	Algoritmos de genética	K-means	Hibrido	Ontología	Inserting/removing	Alterina	Dimina	Sortina	Stretch text	zoom/Scale	Layout	Multimedia	text	Link Sorting/ordering	Link Annotation	Combinational	Link Generation	Guidance	Link Hiding	Map
[28]	✓			✓					✓						✓																								
[29]	✓				✓							✓	✓	✓	✓	✓																							
[30]	✓			✓						✓																	✓	✓											
[31]			✓						✓											✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	

1.6.3. Trabajos relacionados

1.6.3.1. Sistemas de Recomendaciones

Los sistemas de recomendaciones o SR son una subclase de sistema de filtrado de información que tratan de predecir el rating o preferencia que ese usuario le daría a un elemento o artículo (Item) que aún no habían considerado, estos ítems pueden representar cualquier cosa programas de televisión, videos, textos, entre otros [22], [60]. Utilizando un modelo construido a partir de las características de un ítem (basadas en el contenido enfoques) o el entorno social del usuario (métodos de filtrado colaborativo).

Este tipo de sistemas no son un tema nuevo de investigación, varios trabajos han aprovechado sus bondades para llegar de una manera mucho más personalizada a sus usuarios y los han utilizado en un sin número de campos, desde la recomendación de contenidos en salud como se hace en [64]–[66], o para otro tipo de especialidades con compras online como Amazon, hasta en la realización de sistemas que responden a los usuarios múltiples preguntas como Yahoo! Answers presentado en [67]; pasando por sistemas de recomendaciones para libros, películas como Netflix, programas de televisión hasta para información para investigadores [68]–[72].

En [73] se presenta una conceptualización muy completa de los sistemas de recomendaciones y un estudio del estado del arte de los mismos. Este clasifica los sistemas de recomendaciones en tres grupos: (1) basados en contenido o aquellos que utilizan información de los ítems que el usuario ha calificado para recomendar ítems similares que puedan interesarle; y (2) filtros colaborativos que, en el caso de ser usuario-usuario recomiendan al usuario elementos que fueron atractivos para otros individuos con gustos similares, a su vez, un filtro colaborativo Item-Item sigue la misma idea, pero basada en ítems similares. Para calcular dicha similitud entre usuarios, el filtrado colaborativo depende de las calificaciones pasadas de ambos usuarios ya que estos se consideran cercanos si han dado calificaciones similares a los mismos elementos. Finalmente (3) representa los sistemas híbridos que combinan los dos anteriores [74], [75]. Otros trabajos como [76][77] representan extensiones de estos mecanismos de recomendaciones bajo aproximaciones basadas en conocimiento. Estos últimos se enfocan en entregar recomendaciones basados en especificaciones explícitas del tipo de contenido que el usuario solicita al sistema.; y los basados en casos [45], [78], [79], en los cuales los usuarios solicitan los ítems al sistema a partir de sus propios objetivos.

En síntesis, los trabajos anteriores resumen los conceptos básicos de los sistemas de recomendaciones aplicados a diferentes dominios y como se puede apreciar, existen sistemas de este tipo para entornos de publicidad. Sin embargo, no muchos han incluido información de contexto y los que lo han hecho no han definido un dominio de variables enfocadas directamente a aplicarse dentro de la recomendación.

1.6.3.2. Sistemas de Recomendaciones Conscientes del Contexto

En [42], [61], [71], [80], [81] se presenta los sistemas de recomendaciones basados en contexto o CARS donde además de la información de los usuarios y de los items, se utiliza información contextual para alimentar el sistema de recomendaciones, dicha información contextual es organizada jerárquicamente e incluida dentro de una ontología que permita de una forma semántica encontrar la similitud entre los contextos.

El incluir información contextual en los sistemas de recomendaciones se ha convertido en un tema importante de investigación en los últimos años. En [46], [75], [82], [83] enfatizan en la forma como el contexto puede influenciar las decisiones de los usuarios y aunque presentan algunos casos de estudio de sistemas implementados, no se enfocan en la construcción para un ambiente específico. Por otro lado, este tipo de sistemas han sido implementados para la recomendación de viajes, material educativo, música, películas, entre otros,[81], [84]–[86]. Ellos muestran la importancia de este campo de investigación y aunque no se enfocan en el dominio específico de salud pueden aportar información relevante para la inclusión de datos de contexto al sistema.

Al considerar información contextual dentro de los sistemas de recomendaciones cambia la matriz de factorización bidimensional común de *Usuario X Item* a una matriz multidimensional *Usuario X Item X Contexto*, donde el contexto puede estar conformado por una o más variables complicando un poco el modelo matemático de los SR clásicos y obligando a adoptar mecanismos que permitan lidiar con el sin número de variables que pueden incluirse en el contexto [48][49].

En el libro “*Context-aware recommender systems*” [83], mencionan la posibilidad de seguir usando una matriz bidimensional $U \times I$, con el ánimo de seguir trabajando con los recomendadores clásicos. El proceso de reducción de dimensionalidad consta de 2 pasos: en primer lugar, se establece un valor para la variable contextual y posteriormente se selecciona la matriz de factorización bidimensional que cumpla con dicho valor de contexto. Cabe aclarar que este trabajo sólo se centra en la presentación del concepto de reducción de dimensionalidad y no en un Sistema de

Recomendaciones específico, no es claro cuál debe ser el mecanismo utilizado para realizar dicha reducción, en algunos trabajos de investigación se presentan algunas formas para realizar dicho proceso, entre las que se incluyen árboles de decisión aleatorios, razonamiento basado en casos, entre otros [44], [52], [87][88].

Finalmente, en [59], [62], [83] se tiene un enfoque algo diferente, pues hasta el momento todos los trabajos que se han presentado han indicado que el orden para generar recomendaciones usando contexto consiste inicialmente en hacer una reducción de dimensionalidad y luego utilizar la matriz resultante en un sistema de recomendaciones clásico. Por el contrario, este trabajo indaga sobre el mejor momento de realizar la reducción de dimensionalidad y expresa tres posibilidades:

1. Hacer un pre-filtro: Así como lo mencionan en los trabajos anteriores.
2. Hacer un post-filtro: en este caso primero se usan los datos del $U \times I$ sin considerar la información contextual y al resultado se le practica una reducción de dimensionalidad.
3. Incluir la información de contexto directamente en el modelo del SR. Este trabajo hace evidente la necesidad de determinar el momento justo para realizar la reducción de dimensionalidad, exponiendo que no existe un punto para hacerlo que funcione bien para todos los SR, y por tanto es necesario hacer pruebas de ensayo y error para identificarlo.

1.6.3.3. Sistemas de Recomendaciones en Salud

En la literatura se encuentran diferentes trabajos de investigación orientados a sistemas de recomendaciones en el dominio de la salud. Existen sistemas como [11], [17], [25], [89]–[93], orientados a la promoción de actividad física y entrenamiento personalizado, sus recomendaciones se basan en el perfil de los usuarios. También permiten la formación de grupo de usuarios con características similares, y las recomendaciones son basadas en las características generales del grupo. Una funcionalidad importante es que permiten a los usuarios compartir información sobre su progreso. Para realizar las recomendaciones los sistemas utilizan algoritmos avanzados de información, minería de datos y otras técnicas computacionales para apoyar las decisiones de salud para los usuarios con condiciones médicas como la diabetes, presenta un enfoque de recomendaciones de conocimiento médico basado filtrado colaborativo.

Un tipo de sistemas de recomendación son los “Context Aware Recommender System” llamados **CARS**, estos sistemas aprovechan la información adicional del contexto del usuario para ofrecer las recomendaciones más precisas sobre los diferentes

productos, servicios y recursos. Este conocimiento puede obtenerse normalmente de sensores en dispositivos wearables o dispositivos móviles. Los CARS parten del hecho de que los usuarios interactúan con el sistema dentro de un "contexto" particular y cambiante. Estos tienen un enorme potencial en la promoción de la salud apoyando el incremento de la adherencia de usuarios a los programas de hábitos saludables para personas con enfermedades no transmisibles ENT como la Diabetes o cardiovasculares.

Las técnicas de recomendación más usadas por estos sistemas contextuales son filtrado colaborativo, basado en contenido y algunos usan algoritmos supervisados como árboles de decisión y KNN.

Los siguientes son trabajos de investigación orientados al dominio de la salud [41], [84], [94]–[100], los sistemas aquí mencionados ofrecen a los usuarios los beneficios de la personalización según un contexto detectado, estos toman datos de dispositivos como acelerómetros para identificar si el usuario está realizando su actividad, también usan tecnologías como GPS (Global Positioning System) o NFC (Near Field Communication) para obtener datos de localización. Los CARS facilitan las recomendaciones sociales, ya que permiten identificar con quien está el usuario, de esta manera el sistema no solo hará recomendaciones individuales sino grupales que motiven a los usuarios a continuar en el programa de salud.

El número de aplicaciones móviles disponibles para administrar condición de salud de usuarios (pacientes) crece rápidamente, abarcando desde las más sencillas, que únicamente permiten introducir el valor de algún dato clínico como glucemia a las diferentes horas del día, hasta las más complejas, que permiten no solo registrar las dosis de insulina, sino otros parámetros como: los hidratos de carbono consumidos, el ejercicio físico realizado o pequeñas anotaciones con información relevante. Incluso existen algunas que disponen de calculadora de calorías, esfuerzo, dosis de medicaciones. Independiente de cuál sea la aplicación escogida, hay que tener en cuenta que estas aplicaciones móviles, más allá de facilitarle al profesional el control del tratamiento, deben ayudar a las personas a interpretar por sí mismas los resultados obtenidos en el programa o tratamiento que siguen y a desarrollar la habilidad de modificar su tratamiento haciendo uso de dispositivos portables.

Con estos sistemas se busca hacer recomendaciones apropiadas para capacitar al usuario en hábitos saludables y manejo de la enfermedad. Para este trabajo de grado es necesario la evaluación y análisis de distintos sensores, dispositivos y/o

herramientas TIC existentes, que apoyen programas de salud orientados a promocionar hábitos saludables específicamente actividad física.

1.7. Brechas

Una vez realizado el proceso de análisis del estado del arte, se identificaron las brechas que se resumen a continuación:

- La primera hace referencia al área de investigación, son pocos los trabajos que se han realizado relacionados con sistemas de recomendaciones consientes del contexto para la promoción de la salud y prevención de enfermedades. Además, los trabajos relacionados con salud y TIC, son principalmente evaluados por expertos en salud, pero no se evidencia evaluación software en cuanto a usabilidad y satisfacción del usuario. Por otro lado, los sistemas de recomendaciones siempre miden la precisión de la técnica o del algoritmo, pero falta relacionarlo con la evaluación de los usuarios.
- De la revisión de la literatura se evidencia la necesidad de integrar al sistema de recomendaciones tradicional el componente contextual y por ende evaluar el mejor enfoque y técnica en la promoción de actividad física, para ello se identifican los componentes para la implementación de un sistema de recomendaciones CARS en el área de salud:
 1. Modelado de usuario y contexto mediante la ontología OntoCOCARE, que servirá como base de conocimiento para el sistema, así se disminuirá el efecto negativo de iniciar en frío, es decir de tener nuevos usuarios.
 2. La decisión del enfoque, ya que se requiere una matriz de más de 2 dimensiones, primero un conocimiento previo del usuario y parámetros de su registro médico personal, además considerar los datos del contenido y parámetros del contexto.
 3. Técnica o algoritmo de minería de datos u otros, que permitan generar una recomendación de contenidos multimedia precisa y satisfactoria.

Hasta el momento no se ha encontrado un trabajo que ofrezca una solución a estas necesidades y además que involucre el área de salud.

1.8. Contribuciones

1.8.1. Ontología OntoCOCARE

Se generó un modelo de información contextual a partir de la adaptación de ontologías existentes en la literatura, con el objetivo de permitir su utilización en sistemas de recomendaciones contextuales para promoción de actividad física.

1.8.2. Algoritmos para la predicción de preferencias de usuarios usando contexto

Se seleccionaron los algoritmos que usan la información de usuario, ítem y contexto para entregar una mejor recomendación a los usuarios. Para lograr esto se han utilizado diferentes ecuaciones y medidas de similitud según el caso. Al implementarse dichos algoritmos permiten generar recomendaciones basadas en contexto para promoción de actividad física.

1.8.3. Implementation de CoCARE

Se logró construir un prototipo de sistemas de recomendaciones basado en información contextual para el dominio de la salud y que puede ser extendida a otros dominios de aplicación.

1.8.4. Publicaciones

Tabla 2. Publicaciones

Conferences and Journals	Paper
Revista S&T U. ICESI (Tipo C) & Cita 2015	Towards a Standardized User Model for Personalized Systems in Health [101]
Revista de Universidad de Medellín (Tipo A2) 2016	Modeling of a context-aware system to support interventions in physical activities and healthy nutrition [102]
Euro American Conference on Telematics and Information Systems EATIS 2016	Framework for data model to personalized health system [103]
The annual IEEE International Conference on Tools with Artificial Intelligence (ICTAI 2017)	RecOnto: An ontology to model recommender systems and its components [104]

international conferences on personalized health- Phealth 2017	Architecture and user-context models of CoCARE[94]
International Conference on Case-Based Reasoning (ICCBR 2017)	Recommendation System based on CBR algorithm for the Promotion of Healthier Habits [105]
Lacpei International Multi-Conference 2017	Smart platform of recommendation in social networks for education in habits, lifestyles and physical exercise for a patient with diabetes [106].

1.9. Conclusiones Capitulo 1

Para concluir, este capítulo no solo define el problema a abordar en todo el trabajo de grado, sino que contribuye a los grupos de investigación e investigadores en este tipo de temas, ya que entrega un mapeo sistemático actualizado que permite evidenciar distintas brechas y nichos de investigación que se requieren trabajar. Por otro lado, se definen algunos conceptos y puntos de partida para la investigación de sistemas de recomendaciones y sus distintas técnicas. La metodología que se menciona en este capítulo, describe como se estructuran los siguientes capítulos de esta tesis iniciando por la ontología que modelará los datos del usuario y el contexto, seguido de la evaluación de distintos algoritmos y finalmente la prueba del prototipo final que llamaremos CoCARE

2. Capítulo 2. Modelado de Usuario Consciente del Contexto

2.1.1. Introducción Capítulo 2

Como se mencionó en el capítulo 1, para el desarrollo de sistemas de recomendaciones contextuales, se requieren datos organizados (modelado de datos) de: usuario, ítem y/o contexto. Para modelar los datos, se crea una ontología que incluye características del usuario e información de su contexto para el dominio de salud. Esta ontología se basa en otras ontologías, empezando por una de alto nivel BFO (Basic Formal Ontology), RecOnto para crear sistemas de recomendaciones, SNOMED en el dominio de salud y PMO (Precision Medicine Ontology) , PACO (Physical Activity Concept Ontology), EFO (Experimental Factor Ontology) y EXO (Exposure Ontology), para el subdominio de la actividad física. Con la ontología creada OntoCOCARE (Ontología para el cuidado contextual o basado en el contexto), se modela ordenadamente la información del usuario y su contexto para implementar el sistema consciente en el contexto con base en un modelo organizado de datos.

En este capítulo se dará respuesta a las siguientes preguntas:

1. ¿Qué datos se requieren del dominio de salud para representar el usuario y el contexto?
2. ¿Cuáles datos son los indicados para modelar el sistema de recomendaciones consciente del contexto?
3. ¿Cómo organizar/modelar los datos?
4. ¿Por qué usar Ontologías y cuáles son sus beneficios?
5. ¿Qué ontologías del dominio de salud y de sistemas de recomendaciones pueden adaptarse para este sistema?
6. ¿Cómo crear una ontología para un sistema de recomendaciones consciente del contexto en el dominio de la salud?

En este capítulo se hace un breve resumen del concepto y los tipos de ontologías que existen con base en el dominio de la salud y específicamente actividad física, así como a los diferentes enfoques ontológicos que pueden utilizarse para conceptualizar el contexto. Para esta tesis, resultan de especial interés las ontologías de aplicación que más adelante se describen, soportadas en la estructura de una de alto nivel. Por otra parte, para facilitar la interpretación del trabajo desarrollado, se describen conceptos y relaciones que soportan el desarrollo, implementación y utilización de las

distintas ontologías adaptadas para crear que la que se propone en esta tesis, la cual lleva el nombre de OntoCOCARE. Se describen los criterios de selección de las ontologías que se integraron para crear la ontología del Sistema de recomendaciones consciente del contexto como apoyo a programas de actividad física llamado CoCARE.

2.1.2. Definiciones

2.1.3. Modelado de Usuario Consciente del Contexto

Para el desarrollo de los sistemas de recomendaciones, se requiere tener un modelo organizado con información personal de cada usuario incluyendo sus gustos y preferencias, además de datos tomados del contexto del usuario de manera no invasiva y que se relacionan con su salud y sus diferentes roles [46]. Esta información estructurada mediante diferentes métodos, siendo el método de 5 preguntas llamadas “las 5ws” [82], los modelos de contexto jerárquicos [107], [108], modelo de proceso de contexto adaptativo y la consulta con expertos los más comunes.

En esta tesis se propone un método para seleccionar los datos más relevantes para los sistemas de recomendaciones en el área de salud considerando las cuatro aproximaciones mencionadas anteriormente, y que aborde las 3 dimensiones del modelo de usuario: usuario, ítem y contexto. Este método consiste en dos modelos, un modelo conceptual y un modelo de proceso.

La Figura 3 representa el modelo conceptual de alto nivel del método propuesto, definiendo un modelo de 4 capas que describe el contexto en salud que experimenta un usuario. Este método nace a partir de la definición de contexto mencionada en [109], donde se hace referencia puntual a los lugares donde se encuentra el usuario, las actividades que realiza y las personas y objetos que lo rodean [92], [107], [110]. Estos elementos se tomaron como referencia para generar un modelo en cebolla, donde se agrupan los diferentes contextos que influyen en la salud de las personas: contexto digital (dispositivos que tiene el usuario), contexto personal (¿quién es? y ¿por qué usa el sistema?), contexto físico (¿qué hace?, ¿dónde está?) y factores de riesgo en salud que son cualquier rasgo, característica o exposición de un individuo que aumente su probabilidad de sufrir una enfermedad o lesión [111].

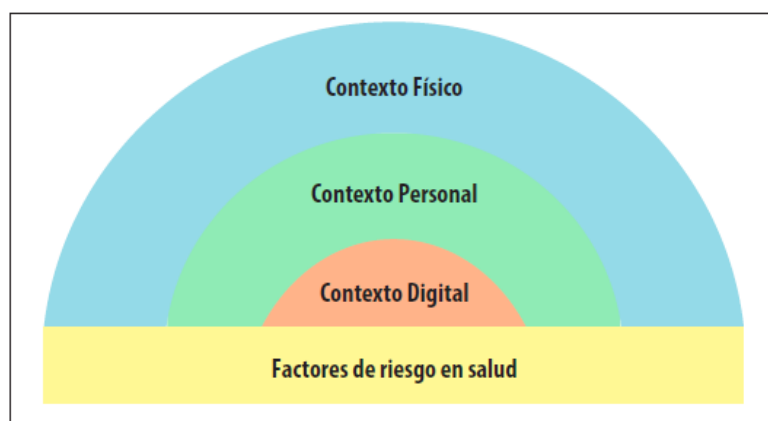


Figura 3. Modelo Contextual incluyendo dominio de la salud
(Fuente: elaboración Propia)

Ya que el contexto contempla muchas características del usuario, se hace difícil que el sistema solicite todos estos datos al usuario de manera manual. Por esta razón se sugiere modelar la toma de datos, la clasificación y la adaptación de dichos datos, para presentarle la mejor respuesta que el usuario desea tener. Se realizó una adaptación del modelo del proceso de adaptabilidad del contexto [112] con el fin de obtener una serie de pasos como guía en la construcción del modelo del contexto en el área de salud. La adaptación se constituye en el modelo de proceso que consta de 4 etapas y toma el nombre de Método de adaptabilidad y personalización del contexto, como se observa en la Figura 4.



Figura 4. Método de adaptación
(Fuente: elaboración propia)

Las cuatro etapas del método se describen a continuación:

- Primera etapa, conceptualización del contexto [92], [110]. Esta etapa se utiliza el método de las 5WS [82] aquí se definen y seleccionan los datos relevantes para el sistema, como ubicación, temperatura, actividades, etc. [113].
- Segunda etapa, computación del contexto. Aquí se debe realizar la selección de la tecnología para sensar el contexto, la detección o el sensado de los datos que se determinaron en la primera fase, su procesamiento y su almacenamiento. Esto se hace con base en lo propuesto por [113] y se realiza mediante una comparación de tecnologías para seleccionar la mejor.
- Tercera etapa, adaptación de contexto. Esta se organizó en dos partes: la primera incluye el modo de clasificación: aquí se hace referencia a un proceso manual de adaptación, es decir, que el sistema antes de realizar una acción pregunta lo que el usuario desea. La segunda parte corresponde a la personalización: esta etapa se refiere al proceso automático en que el sistema aprende y realiza acciones en el momento apropiado cuando el usuario quiera que ocurran, para esto se usa el marco de referencia llamado Ciclo de personalización contextual Copernik [84].
- La última etapa hace referencia a cómo toda la información va a ser mostrada al usuario, teniendo en cuenta: facilidades de uso, accesibilidad, problemas de discapacidad y que sea amigable al usuario. En esta etapa se usa la metodología del diseño centrado en el usuario DCU [114][115]. Esta parte será mostrada más adelante con imágenes del funcionamiento del prototipo del sistema (ver Sesión 4).

Los datos del contexto se clasifican en 5 grupos, de acuerdo a las 5W. En la Tabla 3 se muestra la clasificación de los datos que es necesarios obtener, para que el sistema pueda recomendar al usuario la mejor intervención TIC. Para este caso se tienen en cuenta los datos asociados a actividad física; pero la figura 2 puede ser usada para cualquier tópico en el área de la salud.

Tabla 3. Clasificación de datos contextuales.

<i>¿Quién?</i>	<i>¿Dónde?</i>	<i>¿Qué?</i>	<i>¿Cuándo?</i>	<i>¿Por qué?</i>
Datos de usuario: peso, ritmo cardíaco, etc.	Localización general: casa, trabajo, universidad, etc.	Actividades: cocinar, trabajar, etc.	Tiempo/ temporada: vacaciones, festivos, laboral.	Razones / deseos: bajar de peso
Personas cercanas: compañeros de trabajo, hijos, etc.	Localización específica: cocina, dormitorio, oficina, etc.	–	–	–
–	Características de los lugares: temperatura, clima, etc.	–	–	–

En la Tabla 4, se muestran datos más representativos del dominio de salud seleccionados con base en el modelo anteriormente descrito. Estos datos se describen con más detalle en los artículos publicados de este apartado [102][101], [103].

Tabla 4. Caracterización del modelo de usuario.

Perfil genérico	Perfil psicológico	Otras características
<i>Información genérica</i>	<i>Hábitos</i>	<i>Objetivos del usuario</i>
Nombre completo Correo electrónico Teléfono Estatura Peso Índice Masa Corporal Número de identidad	Orden de su día Gustos Aptitudes Intereses Hobbies Hábito alimenticio Actividad física Vicios Cosas que no le gustan Tiempo de vacaciones Horas laborales Horas familiares	Promedio aceptable de actividad física Dieta balanceada
<i>Información demográfica</i>	<i>Creencias</i>	<i>Otros</i>
Fecha de nacimiento Género Raza Estado civil Lugar de nacimiento Nivel académico Ocupación Edad Lugar de residencia	Ideología política Ideología religiosa Valores	Estrato socioeconómico Registros de navegación Dispositivos de acceso Idiomas Convivencia familiar Conocimiento adquirido Creación de cuenta
<i>Limitaciones físicas</i>	<i>Otros</i>	
De tipo auditivo De tipo visual De tipo neurológico De tipo motriz	Estilo de aprendizaje Trazos de personalidad Pequeña autobiografía Fobias	

Partiendo de la información contenida en Tabla 3 y Tabla 4, por medio de la metodología Delphi [102], se crean unas tablas de comparación (x vs. y) para definir de manera preliminar las relaciones entre cada uno de los elementos característicos considerados. En [101], [102] contiene las relaciones y tablas comparativas creadas, además de la descripción de la metodología Delphi utilizada para esta parte del desarrollo de esta tesis y el protocolo de las entrevistas a los expertos.

2.1.4. Representación formal del modelo de datos de usuario basado en contexto

Los datos seleccionados mediante el método anterior, se deben conceptualizar y representar formalmente, para ello deben modelarse conceptos que permitan usar diferentes fuentes de datos, y establecer adecuadas relaciones entre ellos, logrando dar mayor formalidad y expresividad al sistema de recomendaciones. Para ello, se deberá crear una ontología, ya que ellas se usan para representar modelos conceptuales de datos y definir los términos y relaciones de vocabularios o datos

de un tema o dominio de interés particular, por medio de símbolos, reglas, axiomas y/o combinación de ellos. Existen múltiples ontologías con distintas características y definidas para dominios diferentes, con la capacidad de expresar relaciones y restricciones. Sin embargo, no se cuenta con una ontología para representar el modelo de usuario basado en contexto en el dominio de la salud.

Para esta investigación, la ontología se implementará en un sistema de recomendaciones, por esta razón se realizó una breve revisión de la literatura como apoyo a la toma de decisiones en la selección de las ontologías y la construcción de OntoCOCARE. A continuación, se describen algunos modelos de sistemas de recomendación y principalmente aquellos que proponen modelos basados en ontología. Han sido organizados en dos grupos principales, sistemas de recomendación clásicos y sistemas de recomendación conscientes del contexto, en los que se proponen diferentes enfoques basados en ontologías para el modelado de sistemas de recomendación [116].

2.1.5. Sistemas de recomendaciones basados en ontologías.

Con respecto al sistema de recomendaciones clásico basado en una ontología “probabilistic multimedia ontology”, se encontraron varios trabajos, entre ellos está el de Ajmani en el 2013 [117] que propusieron un sistema de recomendación basado en una ontología que utiliza la técnica de Filtrado Colaborativo para dar recomendaciones de diferentes tipos de prendas para la venta en tiendas. La recomendación se realiza en dos (2) etapas, la primera determina la personalidad con la relación entre la parte de la cara (ojo, piel, cabello, etc.) y las temporadas de color. A continuación, la recomendación de prenda basada en los materiales, el color, el diseño, la artesanía y las preferencias del usuario (ajuste ajustado, ajuste suelto, etc.). Los autores en [118] proponen una ontología Gene Ontology Annotation (GOA) con base en el dominio médico, es una herramienta para los RS de salud como apoyo en la toma de decisiones del diagnóstico clínico. Un enfoque similar es propuesto por Terziev en el 2015 [116], cuyo objetivo es reducir el tiempo empleado en la búsqueda de información en el dominio específico, ya que se requieren muchos datos del dominio específico para hacer un diagnóstico y recomendaciones adecuadas. Los autores proponen un RS basado en ontología que proporciona información relacionada con el caso médico basada en documentos recopilados en casos médicos similares acumulados.

Siguiendo con el modelado de sistemas de recomendación, en [79] se describe un marco para construir sistemas de razonamiento basado en casos (CBR). Es una herramienta para desarrolladores que puede implementar un prototipo con

diferentes configuraciones de sistema CBR en entornos académicos. Jcolibri2 puede utilizarse y extenderse en otros prototipos hechos en Java.

Por otro lado, consideramos que los sistemas de recomendación basados en el contexto, se basan en ontologías contextuales que admiten información contextual basada en un dominio específico. En [119] los autores proponen un sistema de turismo móvil basado en ontología y basado en el contexto. Usan la ontología en la aplicación móvil de turismo al predecir la ubicación del usuario antes de que llegue a ese lugar y razonar la ontología en función de eso. Agregue que restringen el área de interés (AOI) mejorando el tiempo de respuesta del sistema al limitar el número de puntos de interés (POI) según la velocidad de la red y la velocidad del usuario.

Otros autores proponen ontologías para el dominio de la educación [120]. En [121] un sistema de recomendación en un contexto de aprendizaje electrónico, recomienda acciones a un alumno en función de las acciones de alumnos anteriores. El sistema puede proporcionar una recomendación para materiales de aprendizaje en línea o accesos directos. Estas recomendaciones se basan en la ontología que comprende las actividades de los alumnos anteriores y otras ontologías como los estilos de aprendizaje de los alumnos, el conocimiento que se descubre a partir de los patrones de navegación del alumno, las características del dispositivo y la información contextual.

Por otro lado, se ha evidenciado que para modelar los datos en el dominio de la salud no es suficiente el uso de una sola ontología, es por eso que algunos investigadores han integrado diferentes ontologías en una. Un caso es [120], los autores definen una ontología “ontology-based method that combines low-level primitives of behavior” compuesta de 2 ontologías, basadas en las partes del cuerpo, éstas integran la información del paciente, los tratamientos médicos, el departamento de salud al que ingresa, los síntomas, las enfermedades, las relaciones de los elementos de la ontología aumentan con la iteración del usuario, por ejemplo, una enfermedad como la gripe, que puede tener. Varios tratamientos y diferentes departamentos.

En [122] los autores implementan una ontología compuesta por cinco (5) ontologías propias en el dominio de la televisión. El objetivo de la ontología es proporcionar contenido recomendable a la audiencia esperada o más probable según la importancia, el interés, las características del usuario, el contenido, los dispositivos, los elementos de la televisión, la ubicación, las condiciones ambientales y las relaciones entre ellos.

Los autores de [123] proponen un modelado semántico de servicios basados en OWL-S. El objetivo de este trabajo fue mejorar el modelado del servicio con información de contexto (información del usuario, información del servicio e información del entorno). Dicho modelado se centra en adaptar la composición del servicio a los requisitos del usuario en relación con el contexto (capacidades del dispositivo, ubicación del usuario, etc...), así como al contexto proporcionado por el entorno (conexión inalámbrica, red cableada, etc...).

En [124], los autores se centran en la implementación de ontologías para aplicaciones móviles, integrando diferentes ontologías como: OWL-Time, las ontologías de dominios (4) de; deportes, turismo, clima y transporte público.

Sin embargo, los trabajos solo usan ontologías para modelar el usuario, ítem o información de contexto de manera independiente. Por otro lado, las ontologías propuestas en estos trabajos son propietarias, no están disponibles para su uso, no se evidencia que estén creadas bajo el criterio de ontologías de alto nivel, o reconocidas en el dominio descrito o que hayan sido socializadas o usadas en otras investigaciones.

Es por esta razón, para esta tesis se propone crear una ontología en el dominio de la salud específicamente para actividad física, que permita el modelado de datos de un sistema de recomendaciones contextual. Para ello se integran ontologías no solo de dominio sino de otro tipo que consideran los criterios de clasificación y las metodologías de adaptación de ontologías.

2.1.6. Tipos de ontologías y criterios de clasificación

En el 2007, Bräuer clasifica las ontologías con base en tres criterios: especificidad, propósito y expresividad. A partir de estos criterios se establecen diversas categorías [120]:

- A. Especificidad: dominio, core y genéricas.
- B. Propósito: de aplicación y de referencia.
- C. Expresividad; lightweight y heavy-weight (ver Figura)




Figura 5. Clasificación de las ontologías oberle
(fuente: [120])

En estos términos, la ontología que se propone para esta tesis es de aplicación según el propósito, y en cuanto a especificidad y expresividad será de *domain* (Dominio) y *light-weight* (Ligera).

Las ontologías específicas (de dominio) se utilizan en un dominio concreto, para un propósito particular, y tienen baja exigencia de expresividad sustentada en una representación formal ligera propia del dominio en el que se utiliza, donde los miembros de la comunidad ya conocen de antemano el significado de los términos. A diferencia de las ontologías genéricas que pueden ser usadas en diferentes dominios, para propósitos más generales y tienen una alta exigencia de expresividad, soportada por una representación formal *heavy-weight* (Pesada), que deriva de la necesidad de establecer acuerdos precisos sobre el significado de los términos entre los diferentes dominios a relacionar, de manera que se garantice el intercambio de datos y servicios de manera idónea en los lenguajes y culturas involucradas[125].

Tomando como único criterio el nivel de abstracción (Figura 6), que permite clasificar las ontologías atendiendo a su grado de especificidad en: upper ontologies (ontologías de base, genéricas o alto nivel), que definen conceptos aplicables a la mayoría o a todos los dominios; core ontologies (ontologías fundamentales), que definen conceptos compartidos por varios dominios similares o relacionados; domain ontologies (ontologías de dominio), que contienen conceptos específicos a un dominio particular de interés; y application ontologies (ontologías de aplicación), que especializan los conceptos de una ontología de dominio con variantes específicas para una aplicación. Las ontologías con mayor nivel de abstracción (upper ontologies) incorporar el inmenso beneficio de los resultados y metodologías de disciplinas como la filosofía, la lingüística y las ciencias cognitivas. Frente a ellas, las ontologías de más bajo nivel de abstracción y con expresividad ligera, se pueden construir de forma semiautomática [126].

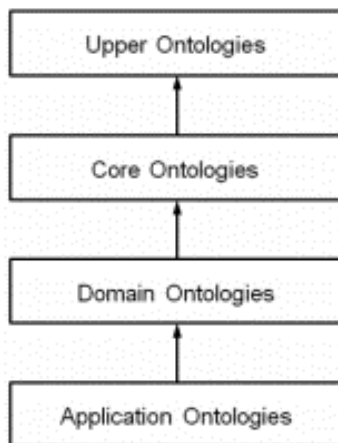


Figura 6. Tipo de Ontologías según el grado de especificidad

(Fuente: [127])

Para la construcción de OntoCOCARE, que es de aplicación se han adaptado ontologías ya existentes en los distintos grados de especificidad, las cuáles se seleccionaron con base en las necesidades del sistema de recomendaciones contextual CoCARE, ellas se describen más adelante. Como ontología de alto nivel se seleccionó BFO (Basic Formal Ontology), en el grado de ontologías fundamentales se cuenta con SNOMED definida para salud, y ontologías de dominio se tienen varias ontologías relacionadas con el campo específico de actividad física como PACO y de sistemas recomendadores contextuales como RecOnto. De la integración de los conceptos más relevantes de cada una de ellas se crea la Ontología que modela los datos del sistema CoCARE.

2.1.7. Metodología para crear la ontología:

Existen muchas metodologías para crear ontologías. Estas metodologías son independientes de lenguajes y herramientas. En [128] [129] [130] se han identificado los pasos necesarios para desarrollar una ontología. Las etapas comunes entre los trabajos son: (1) Diseño: identifica el propósito y el alcance de una ontología y define su estructura (2) Desarrolla: representación formal de la ontología en un lenguaje de desarrollo y reutilización de las ontologías existentes. (3) Evaluación: definir los criterios para validar la ontología. En [131] [129] los autores agregan la fase "mantenimiento" o "iteración", realiza cambios basados en los resultados obtenidos en la etapa de evaluación para mejorar la ontología.

Para crear OntoCOCARE, se usó la metodología OdontoAdapt [120]. Facilita organizar los elementos de los sistemas recomendados y sus relaciones con el dominio de aplicación en forma fácil y eficiente. Además, permite extender la ontología a otras ontologías. Por otro lado, esta metodología ha sido utilizada por desarrolladores de sistemas de recomendaciones. El proceso para construir la ontología se divide en 5 etapas (ver Figura 7):

Siguiendo la metodología anterior, en primer lugar, se hizo una revisión de la literatura sobre las ontologías existentes relacionadas con el dominio de salud, actividad física y los sistemas de recomendación; divididos en clásicos y conscientes del contexto.

Seguido, se definió el objetivo principal: crear una ontología que modele datos basados en los conceptos de salud y de sistemas de recomendación. También se definieron las clases principales relacionadas con los elementos de los sistemas de recomendación (usuario, información contextual, dominio, técnica de recomendación, etc.) y las relaciones entre ellos.

Para implementar la ontología se seleccionó el lenguaje OWL (Web Ontology Language), ya que permite la incorporación con otros lenguajes de desarrollo; Esto nos ayudará a integrar la ontología en un sistema de recomendación.



Figura 7. Metodología OdontoAdapt [120]

(Fuente:elaboración propia)

2.1.8. Selección de Ontologías

Para este trabajo se ha realizado un mapeo de distintas ontologías definidas en www.biportal.biontology.org [132], los conceptos claves se relacionaban con: health, activity, physical activity, context y recommender system.

La siguiente tabla, describe los puntos más relevantes de cada una de las ontologías que se encontraron en la búsqueda.

Tabla 5. Lista de Ontologías Pre-seleccionadas

Clasificación por especificidad	Ontología	Descripción	Número de Clases	Conceptos Generales relacionados

Alto nivel (Upper Ontologies)	BFO (Basic Formal Ontology)	Es una ontología pequeña de nivel superior que está diseñada para usarse en la recuperación, análisis e integración de información en dominios científicos y de otro tipo. Esta ontología no contiene términos físicos, químicos, biológicos o de otro tipo específicos de algún dominio particular.	35	Continuant Ocurrents
Ontologías fundamentales (Core Ontologies)	SNOMED	Modela los conceptos y términos médicos.	347.358	Clinical finding Behavior_finding Health_record Monitoring_status
	Premedonto (Precision Medicine Ontology)	Creada para el dominio de la medicina. El proceso de aprendizaje de la ontología implica extraer el repositorio de PubMed para extraer textos, resúmenes y vocabulario específicos del dominio como fuentes de	543	Lifestyle: Activity of Daily Living Attend Paid Job Bicycling Calisthenics Carrying Climbing Driving Exercise Hard Work

		datos. La información recopilada se agrupa y se resume para determinar los módulos principales. Reutiliza términos y conceptos de NCIT, MESH y IOBC para construir la jerarquía de ontología.		
Ontologías de dominio (Domain Ontologies)	PACO (Physical Activity Concept Ontology)	Es una ontología que modela los conceptos relacionados con la actividad física que puede desarrollar una persona.	224	Activity Daily_living_activity Exercise_leisure_activity
	NCIT (National Cancer Institute Thesaurus)	Un vocabulario para atención clínica, investigación e información pública y actividades administrativas.	146.145	Lifestyle Sedentary Lifestyle Physical Activity

	EFO (Experimental Factor Ontology)	La ontología reúne clases de ontologías de referencia como enfermedad, línea celular, tipo celular y anatomía, y agrega la axiomatización según sea necesario para conectar áreas como la enfermedad con el fenotipo.	22.616	Physical Activity : Motor Activity Activities, Motor Activities Locomotor Activities Activity, Physical Activities Activity, Motor Activities Physical Activities Locomotor Activity Activities, Physical Activities Activity, Locomotor Activities Activities, Locomotor Activities Motor Activities Exercise
	EXO (Exposure Ontology).	Centraliza e integra los “exposure data” para informar la comprensión de la salud ambiental.	148	Physical Activity: include planned activity such as walking, running, basketball, or other sports. Physical activity may also include other daily activities such as household chores, yard work, walking the dog, etc.
		Relaciona conceptos de diversas disciplinas entre ellas: salud ambiental, toxicología, epidemiología, vigilancia de enfermedades y epigenética.		Age Occupation

Ontologías de Aplicación (Application Ontologies)	RecOnto	Modela los conceptos básicos, las relaciones de datos, las reglas para combinar los términos y las relaciones para definir extensiones al vocabulario del dominio.	24	Recommender system Recommender Techniques Context-aware Techniques Knowledge
--	---------	--	----	---

2.1.9. Criterios de selección de ontologías.

Siguiendo con la clasificación de las ontologías (ver figura 3), por cada uno de los niveles se seleccionó una ontología como base para crear la ontología usada en esta tesis OntoCOCARE.

Las ontologías se han empleado con frecuencia para la integración eficiente de la información. Sin embargo, el proceso de crear una ontología sigue siendo una tarea larga y dependiente del dominio de aplicación en algunos casos.

En este trabajo se presenta una forma para seleccionar las ontologías relacionadas con el área de salud, conceptos de usuarios y actividad física, además de la relación de los datos en un sistema de recomendaciones contextual.

Con esta ontología relacionada en el dominio de la salud, se espera reducir o eliminar la confusión conceptual y terminológica entre los miembros de una comunidad en particular que necesitan compartir diferentes tipos de documentos e información. Para ello se debe identificar un conjunto de conceptos y definir los más relevantes que caracterizan el dominio de recomendadores contextuales para promoción de actividad física.

En primer lugar de la página web “bioportal ontology” [133], se seleccionaron las ontologías más relevantes con base en la clasificación de la figura 3. Posteriormente se extrajeron los conceptos de las distintas ontologías relacionados con el dominio de aplicación, para ello se siguió la guía del artículo [134] respecto al reuso de conocimiento y datos.

Las ontologías seleccionadas son: en primer lugar BFO que hace parte del nivel “upper ontology” es importante ya que toda ontología se deriva de un nivel superior. La ontología BFO (Basic Formal Ontology), es la ontología más usada en este nivel y la más común con relación a al dominio de salud.

La siguiente fue SNOMED CT, hace parte del nivel (core ontologies) que para esta tesis se relaciona con el área de salud, se clasifica como una gran ontología que tiene mapeos con otras ontologías como LOINC o PMO (Precision Medicine Ontology). SNOMED presenta propiedades estructurales y comportamientos utilizados lógicos de descripción lo que permite los procesos de inferencia.

Y con relación al dominio o especialidad de actividad física, la principal ontología es PACO (Physical Activity Concept Ontology), de ahí se derivan otras como EFO (Experimental Factor Ontology) y EXO (Exposure Ontology). Son ontologías relacionadas con actividad física que la conocemos como la entidad “Physical Activity” que se deriva de la clase “Activity”. Estas ontologías complementan este trabajo al conceptualizar actividad física; definiendola como cualquier forma de ejercicio o movimiento, puede incluir actividades planificadas, como caminar, correr, jugar al baloncesto u otros deportes.; sin olvidar otras actividades diarias como las tareas domésticas, el trabajo de jardinería, pasear al perro, etc.

Y por última pero no menos importante se definió la ontología RecOnto, donde se relacionan los conceptos generales para el diseño e implementación de sistemas de recomendaciones clásicos o contextuales.

2.1.10. Ontología de Alto Nivel BFO

Las ontologías de alto nivel (upper-ontologies), reflejan la realidad independiente de cada área del conocimiento, de ellas se derivan otras ontologías que representan la realidad en dominios específicos. Las ontologías que se derivan pueden ser creadas desde cero, o pueden usar modelos comunes de otras ontologías que se comparten e integran, donde diferentes ontologías deben ser integradas, por medio de la identificación de elementos similares (conceptos, atributos, relaciones, instancias) dentro de ellas, que agrupe el conocimiento original de las demás ontologías [135]. Una de las ontologías más conocida, pequeña y concreta, que abarca los conceptos y términos relacionados con esta tesis es BFO.

Algunas características básicas de BFO, está diseñada deliberadamente para ser muy pequeña, con el fin de que debe ser capaz de representar de manera coherente

las categorías de nivel superior comunes a ontologías de dominio desarrollados por los científicos en diferentes campos. Al ser de alto nivel no debe contener términos que pertenecen a los módulos de la ontología de dominio específico. No da respuesta a las necesidades terminológicas de los que trabajan en dominios específicos.

La gran ventaja es que apoya la interoperabilidad de múltiples ontologías de dominio creadas en sus términos. Ya que la información recopilada, aunque este en distintos lugares de almacenamiento puede ser entendida y relacionada entre sí, esto mejora la portabilidad de los conocimientos. También proporciona un punto de partida para el desarrollo de la ontología OntoCOCARE, que permite a los nuevos en la ontología se mueva más rápidamente a la clase de preguntas específicas de dominio que pertenecen a sus respectivos ámbitos de competencia, proporcionando un conjunto de respuestas hechas a las preguntas abstractas con que la ontología de nivel superior se refiere (ver Anexo A).

Esta ontología divide sus entidades en dos categorías fundamentales (Figura 8 y Figura 9):

1. Continuants: entidades que permanecen en el tiempo, pueden ganar o perder partes sin embargo sigue existiendo, ejemplo: usted perdió peso, la persona sigue existiendo. No tiene partes temporales.

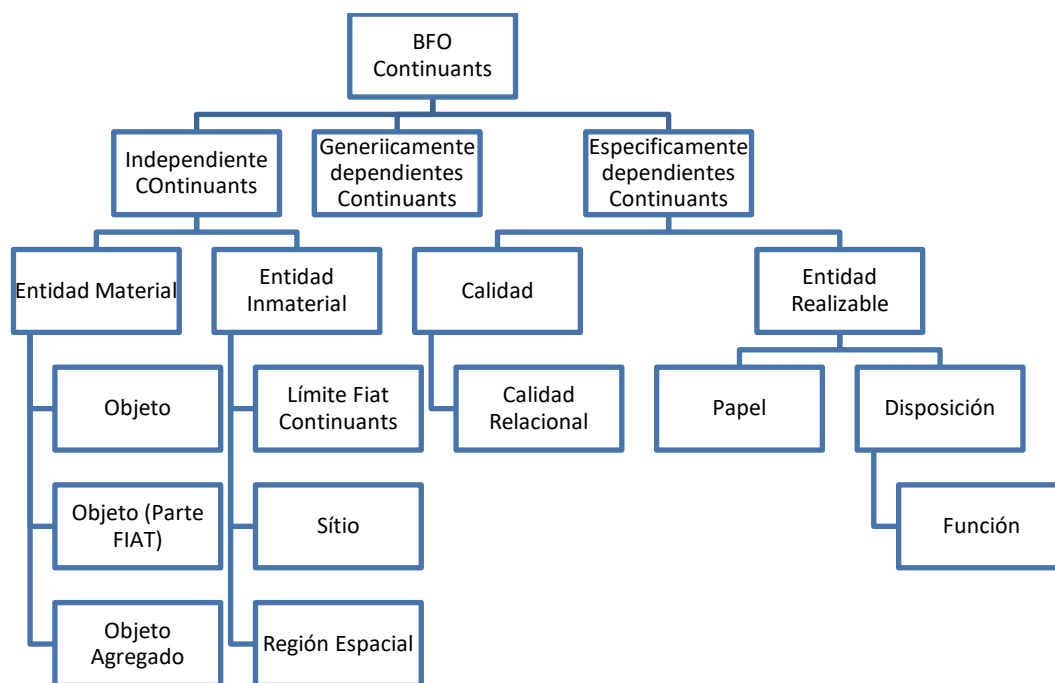


Figura 8. Entidad continuants BFO

(Fuente:elaboración propia)

2. Occurrents: entidades que ocurren en distintos momentos ocasionalmente como eventos, acontecimientos o procesos.
 Por ejemplo: algunas personas (continuant) no realizan actividad física (occurrents), a ellas se les denomina sedentarios.

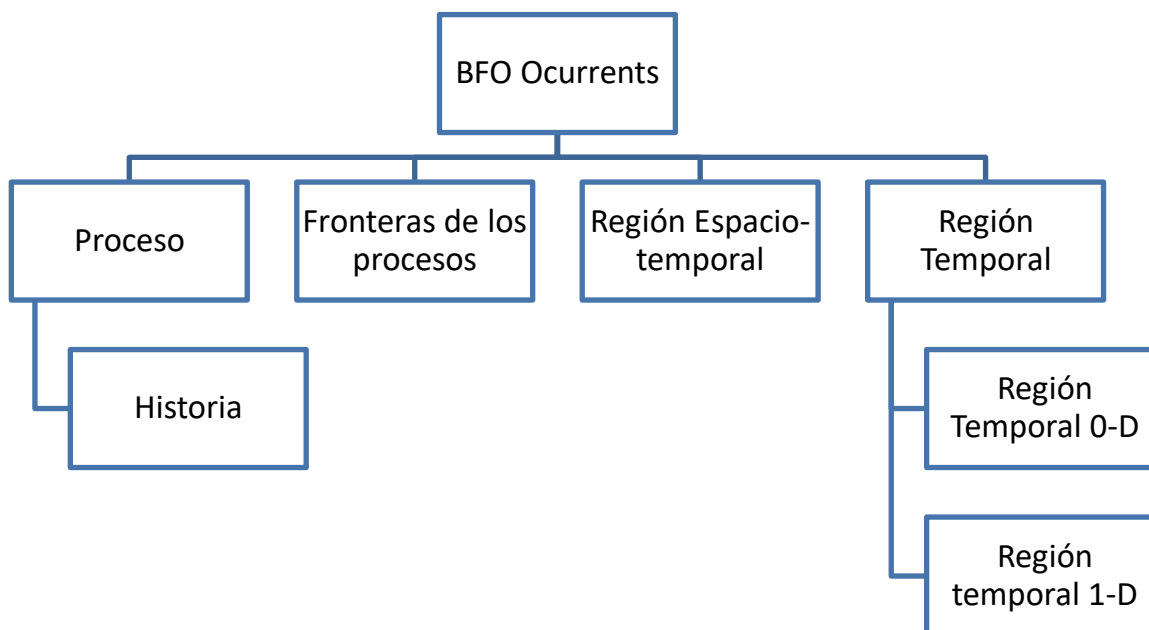


Figura 9. Entidad Ocurrents BFO
(Fuente: elaboración propia)

2.1.11. Ontología SNOMED (Core)

Systematized Nomenclature of Medicine Clinical Terms (SNOMED CT), está diseñada para servir como referencia en la terminología para la agregación y recuperación de datos de atención en salud, estos datos han sido registrados por múltiples organizaciones y particulares (ver Figura 10).

Cada concepto representa un significado clínico único, utilizan dos tipos de descripción para representar cada concepto: el nombre completamente especificado (FSN) y su sinónimo. El FSN representa una descripción única e inequívoca del significado de un concepto y cada concepto puede tener solo un FSN en cada idioma o dialecto.

Un sinónimo representa un término que se puede usar para mostrar o seleccionar un concepto. Un concepto puede tener varios sinónimos. Esto permite a los usuarios de SNOMED CT usar los términos que prefieren para referirse a un significado clínico específico.

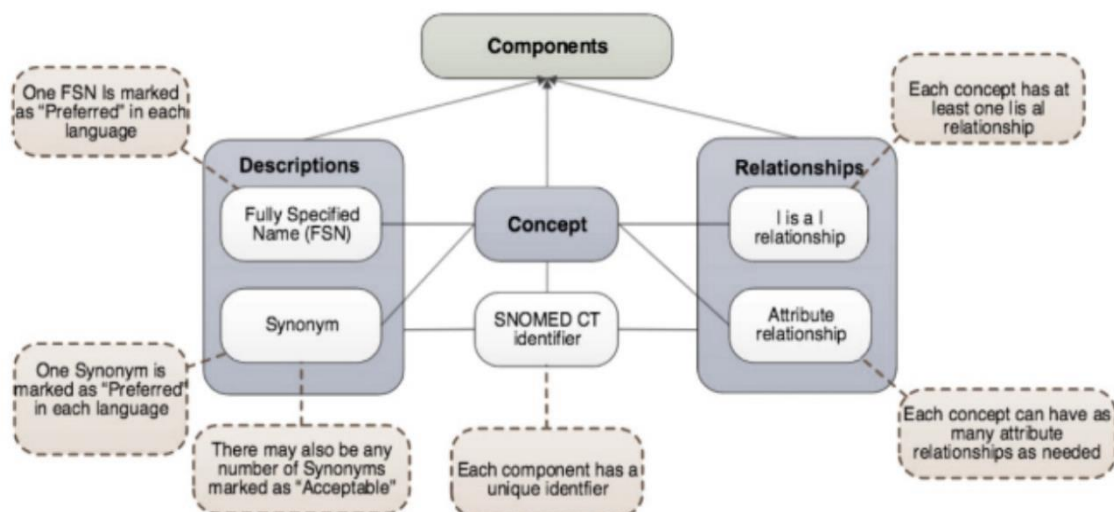


Figura 10. Ontología SNOMED [136]

(Fuente:elaboración propia)

SNOMED CT es fundamental para la documentación clínica, ya que admite la representación de información clínica detallada de una manera que puede procesarse automáticamente.

2.1.12. Ontología PACO (Dominio)

Physical Activity Concept Ontology (PACO) contiene varios conceptos que son requeridos para describir la actividad física[137]. Esta ontología de datos de actividad física proporciona información importante que se estandariza en términos genéricos para los profesionales de esta área.

Este tipo de ontologías son muy útiles para estandarizar descripciones heterogéneas de actividad física y clasificarlas en categorías clínicamente significativas que reflejan la adecuación del ejercicio.

2.1.13. ReCONTO Ontología Contextual

Las ontologías son muy útiles para describir el sistema de recomendaciones, ya que definen los términos básicos, las relaciones de datos, las reglas para combinar los términos y las relaciones para definir extensiones al vocabulario del dominio. Las ontologías se pueden organizar en estructuras jerárquicas, las cuales se pueden

considerar como una de las mejores formas para representar el conocimiento, por esta razón para representar el conocimiento de sistemas recomendadores conscientes del contexto se creó la ontología RecOnto que describe los conceptos, datos y relaciones necesarias para el desarrollo de un sistema. El objetivo principal de RecOnto es crear una herramienta para definir, clasificar los componentes necesarios para la implementación de un sistema de recomendación y filtrarlos según los datos utilizados por este sistema [104].

RecOnto es una ontología para modelar sistemas de recomendaciones. Para aplicarlo a la mayoría de los tipos de sistemas de recomendación, se definieron 2 grupos de sistemas de recomendación basados en [83]. Esta clasificación divide los sistemas de recomendación en 2 grupos, según el número de entradas: 1) algoritmos clásicos, como el filtrado colaborativo, el filtrado basado en contenido y los híbridos, que solo utilizan la información básica de los usuarios y los elementos, y 2) que tienen en cuenta el contexto sistemas de recomendación (CARS). RecOnto define un sistema de recomendación como una colección de módulos que están conectados entre sí. Luego, clasifica cada módulo en función de la información utilizada en ellos. Las principales contribuciones este modelo ontológico son: (1) definir y clasificar todos los elementos que participan en un sistema de recomendación y reutilizar estos módulos en un sistema de recomendación con diferentes dominios; (2) basándose en la información que utilizará el sistema de recomendación, filtre los módulos que no pueden aplicarse en este sistema; (3) defina un modelo que se pueda extender fácilmente para aplicar en otros dominios o agregar nuevos módulos de recomendación (Ver Anexo A).

2.1.14. OntoCOCARE Ontología para el sistema de recomendación contextual en el dominio de salud

En esta sesión se enumeran y describen las clases, relaciones, reglas y lo relacionado con la constitución e intensión de la ontología OntoCOCARE, junto con su descripción. Para el modelado se usará como referencia las siguientes ontologías:

- Alto nivel: BFO
- Dominio: SNOMET
- De aplicación especialidad: Actividad Física
- De aplicación de sistemas de recomendaciones contextuales: ReCONTO, esta ontología permite la adaptación de datos de usuario y contexto de cualquier dominio a un sistema CARS

2.1.15. Clases de la ontología OntoCOCARE



Los datos que se definieron en OntoCocare se dividieron inicialmente en estáticos y dinámicos, según el nivel de variación que tienen con respecto al tiempo y contexto, como se relacionan con la ontología RecOnto [104]. Con base en la división anterior y considerando una ontología de más alto nivel como es BFO se definieron las dos clases principales que son: *ocurrents* y *continuant*, de las cuales se derivan los conceptos relacionados con la información de contexto, ítem y usuario.

La Figura 11, muestra la taxonomía de clases de OntoCOCARE tal y como aparece en el editor de ontologías Protégé. A continuación se describen las principales clases en el Anexo A se describe a detalle la ontología creada.

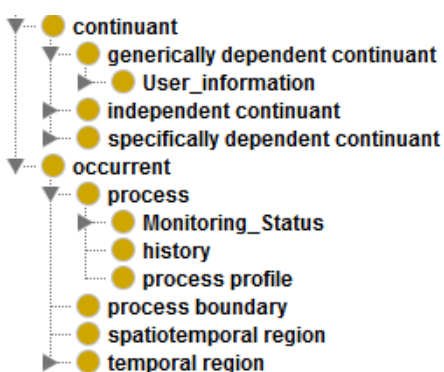


Figura 11. Clases principales OntoCocare

(Fuente:elaboración propia)

La clase *continuants*, hace relación a los conceptos estáticos de los que habla la ontología de sistemas de recomendadores RecOnto [104], son los que se mantienen en el tiempo independiente de los cambios espacio-tiempo; son aquellos que existen y aunque cambien su contexto siguen existiendo en el tiempo. Ejemplo fecha de nacimiento, es una entidad que aporta información del usuario como la edad, pero no cambia en el tiempo.

La clase *ocurrents*, se desarrolla en el tiempo y se producen cambios según el espacio-tiempo. Ejemplo localización, aporta información del usuario temporalmente, en un tiempo indefinido cambiará su posición es decir la región espacio-temporal.

En la Figura 12, se muestran las clases que se relacionan con el conocimiento requerido por un recomendador consciente del contexto. Considerando que este tipo de recomendadores consideran tres (3) dimensiones User X Item X Context, así mismo se relacionaron los datos de la ontología.

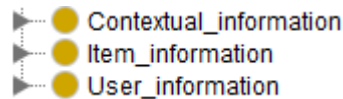


Figura 12. Relaciones con los datos del recomendador.

(Fuente:elaboración propia)

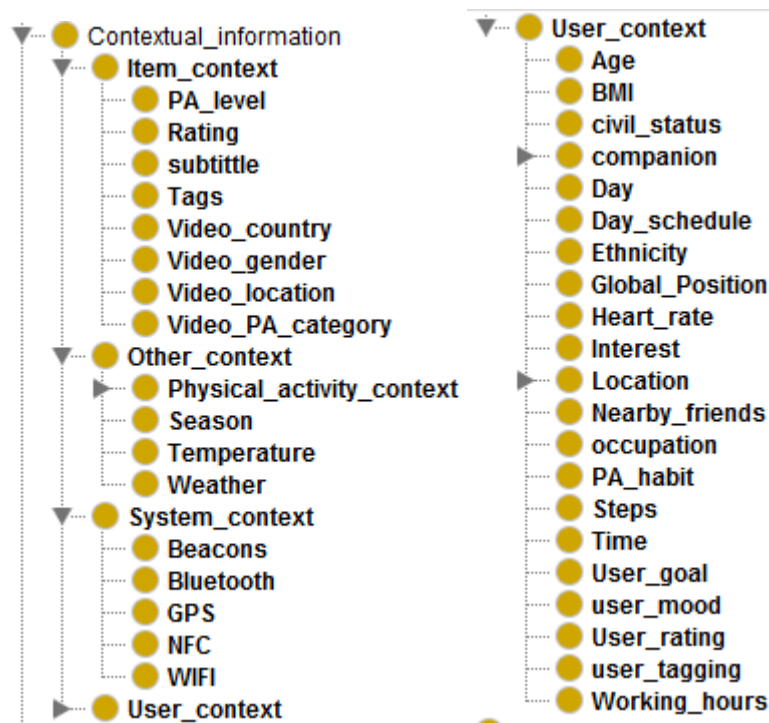


Figura 13. Clases Contextual_information

(Fuente: elaboración propia)

La información relacionada con *Contextual_information* (Figura 13), es variable con el tiempo, por esta razón la entidad hace parte de la clase *Occurrence* (representa a cualquier realización de una actividad), que junto con las entidades de *process*, *spatiotemporal_region* y *temporal_region*, son mutuamente excluyentes del primer nivel de la ontología corresponde al concepto de *perdurant* de la ontología BFO. Un *perdurant* es una entidad en la que solamente algunas de sus partes genuinas están presentes cuando la entidad está presente.

Los datos consignados en la ontología relacionados con salud fueron tomados de Snomed, la gran mayoría corresponden a la descripción del usuario tanto como

individuo como en su contexto, como por ejemplo: *behaviour_finding*, *health_record*, objetos como *BMI (Body Mass Index)*, *Temperature*. Y con respecto a la actividad física se seleccionaron los conceptos con base en la ontología PACO. Por ejemplo: *PA_Level* o *PA_habit*.

Item_information (Figura 14). Se constituye a partir del concepto de *continuants*, se relaciona con la entidad *material entity*, cuyo fin es describir objetos. En esta clase se conceptualiza lo relacionado con los contenidos multimedia que se desean recomendar a los usuarios por parte del sistema recomendador consciente del contexto. Estos datos son independientes del contexto o del tiempo.




Figura 14. Clases *Item_information*

(Fuente:elaboración propia)

User_information. Constituida en la *generically dependent continuant*, relacionada con la entidad *continuant*. También se relaciona con la clase *independent continuant*. La Figura 15, muestra la relación de *clinical_finding* con los demás conceptos relacionados con el usuario y la actividad física.

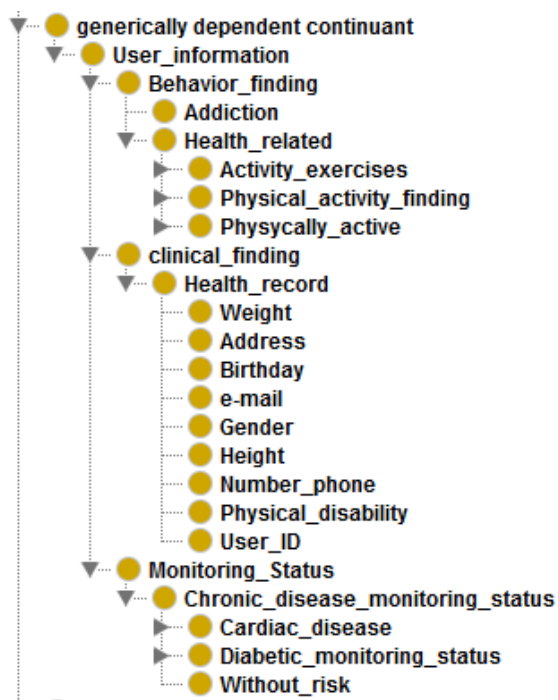


Figura 15. Clases de User_information
(Fuente:elaboración propia)

2.1.16. Data Properties

La Figura 16, presenta, tal y como se muestran en el editor de ontologías Protégé, las relaciones (Data Properties) que pueden establecerse entre individuos de la ontología y sus datos. A continuación, para cada una de estas propiedades se incluye un breve comentario y/o un ejemplo relativo a su interpretación o utilización en la ontología.




Figura 16. Propiedades de los datos
(Fuente:elaboración propia)

- *Description*. Expresa la descripción de un individuo.
- *Quale*. Valor cualidad. Expresa el valor que corresponde a una Región.

2.1.17. Object Property

Siguiendo con base la ontología de alto nivel BFO, las relaciones se dividen en niveles más generales de ahí parten las relaciones específicas como se ve en la siguiente taxonomía (Figura 17).

Se tienen cuatro (4) niveles generales: fundamentales, espaciales, temporales y de participación. En especial las relaciones fundamentales se dividen en tres (3) tipos:

- Universal-Universal: relación de los conceptos de la ontología misma. Ejemplo: age is_a user_information
- Universal-particular: cuando se desea instanciar un datos u objeto de la ontología en algo más específico. Ejemplo: age instance_of birthday
- Particular-particular: se usa cuando desea describir el tipo de instancia u objeto. Ejemplo: cambio de localización ocurrent_part_of proceso de contextualización.

Por otro lado, las relaciones espaciales y temporales, hacen relación con los objetos que sufren cambios dinámicos. Y las de participación es la relación de dependencia para que pueda ocurrir, suceder o desarrollarse dicha actividad, por ejemplo la muerte está relacionada con un persona producto de un cambio temporal, espacial o de contexto. Ejemplo: Geo_location has_participant (GPS).

La Figura 18 muestra, en el modo en que aparecen en el editor de ontologías Protégé, las relaciones (Object Properties) que pueden establecerse entre objetos de la ontología. Las relaciones entre clases y las propiedades de estas clases se reúnen en los predicados de la ontología. A continuación, se describe brevemente cada una de estas relaciones y se incluye, en algunos casos, un breve comentario y/o un ejemplo relativo a su interpretación o utilización en la ontología.

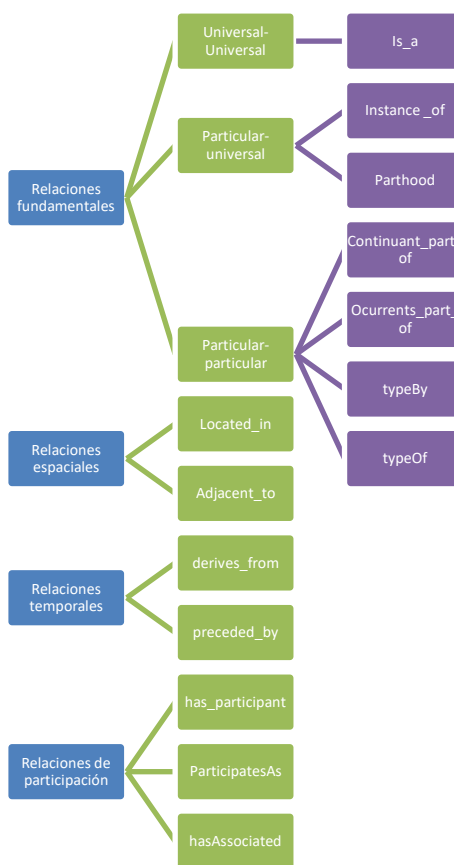


Figura 17. Taxonomía de relaciones
(Fuente: elaboración propia)

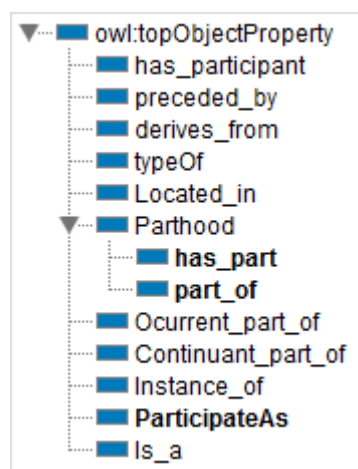


Figura 18. Relaciones ontológicas
(Fuente: elaboración propia)

- *has_participant*. establece la relación entre una entidad continuants que participa en la descripción de un ítem o user (Primitive) y una entidad Occurrence.
- *Proceded_by*. Es la relación entre dos clases secuenciales que al unirse generan una actividad y una depende de la ejecución de la otra clase. Ejemplo: *hearth_rate* *Proceded_by* *Activity_excercises*.
- *Derives_from*. Identifica las subclases que se derivan con dependencia de que la primera exista. Ejemplo: *Moderate_hypertension_control* *derives_from* *cardiac_disease*.
- *TypeOf*. Ejemplo: *specific_location* *typeOf* *indoor*
- *Located_in*. Identifica si una entidad está ubicada o localizada en otra. Por ejemplo: *room* *located_in* *home*.
- *Parthood*. se divide en 2 tipos *has_part* y *part_of*, se usa cuando una entidad hace parte de otra. Por ejemplo *time* agrupa todo lo relacionado con tiempo, ya sea el tiempo que dura una actividad física o la duración del video. Por ende un ejemplo de esta relación es: *Duration* *part_of* *time*.
- *Ocurrent_part_of* y/o *Continuant_part_of*. Cuando una entidad hace parte de otra en su composición y es esencial para que exista. *Height* *ocurrent_part_of* *BMI*, con la talla se calcula el índice de masa corporal.
- *Instance_of*. Cuando una entidad es una parte de otra.
- *ParticipatesAs*. establece la relación entre una entidad continuants que participa en la realización de una actividad primitiva (Primitive) y la entidad Occurrence. Ejemplo: *time* *ParticipatesAs* *PA_duration* el tiempo participa en la duración de la actividad física.
- *Is_a*. hace referencia cualquier representación de la ontología. Ejemplo: *User_Context* *is_a* *User information*.

2.1.18. Discusión Capítulo 2

En este capítulo se tienen dos (2) resultados significativos:

Resultado 1, Modelo de Usuario consciente del contexto. Este modelo permite a otros diseñadores de sistemas recomendadores conscientes del contexto identificar y



seleccionar fácilmente los datos relacionados con su dominio mediante una serie de fases y pasos fáciles de usar. También útiles en el momento de la selección de herramientas, mediadores o bróker para captura de datos de contexto y una guía para definir el tipo de relaciones genéricas entre los datos[138][101], [139].

Resultado 2, Representación formal del modelo de usuario mencionado anteriormente, para llevar a cabo la conceptualización de los datos se creó una ontología llamada OntoCOCARE por medio de la metodología OdontoAdapt. Esta ontología es una adaptación de 4 ontologías muy conocidas, que ya han sido usadas en otros trabajos de investigación, de uso gratuito y que facilitan las relaciones entre los distintos conceptos y clases.

La metodología OdontoAdapt, permitió obtener un modelo de abstracción de sobre los posibles objetos que integran el dominio, seguido del resultado de conceptualización del dominio de aplicación. Los conceptos y relaciones de esta ontología se fundamentan en un conjunto de ontologías que contribuyen a la descripción formal de OntoCOCARE, empezando desde un alto nivel con BFO hasta el nivel de aplicación de actividad física con PACO y de sistemas recomendadores como ReCONTO, usando datos comunes al dominio de salud con SNOTMED. Como resultado se obtiene una representación alterna de los datos y su conceptualización integrados en una plantilla semántica de descripción.

El hecho de construir una ontología acorde a diversas ontologías y contextos, alimenta la conceptualización y enriquece su formalidad aumentando su funcionalidad en otros espacios de investigación. Es como entregar un lenguaje en el dominio de salud aplicado a recomendadores contextuales, nuevo con un vocabulario fácil de entender y de aplicar.

Con este tipo de ontologías adaptadas de otras de alto nivel, son flexibles para compartir datos y por ende conocimiento usando los beneficios de un lenguaje como lo es OWL, que refleja de forma explícita las propiedades y relaciones de los objetos, además de su comportamiento importante para entender, interpretar e inferir datos.

Resultado 3, las ontologías son muy útiles para describir el sistema de recomendaciones, los principales objetivos de OntoCocare: es definir, clasificar los componentes necesarios para crear el sistema de recomendación y filtrarlos en función de los datos utilizados en el sistema de recomendación.

Así, se facilita: a) crear un significado para cada componente del sistema basado en conocimiento; b) definir restricciones para aplicar a cada técnica de recomendaciones usada en sistema de recomendaciones contextuales y c) Definir un sistema de recomendación como relación entre diferentes tipos de información sobre Usuarios, Ítem o contexto y las técnicas clásicas como los algoritmos de recomendación basados en contenido o el filtrado colaborativo. O, las Técnicas de recomendación conscientes del contexto, representadas por algoritmos.

Considerando que el sistema Cocare se diferencia de otras aplicaciones por su información de contexto que representa el conocimiento sobre el entorno del usuario o de los elementos. La Ontología construida en esta tesis contribuye al sistema en modelar este conocimiento dinámico que evoluciona con el tiempo en 5 categorías fundamentales definidas como: 1) Conocimiento que describe a un individuo, por ejemplo, las preferencias del usuario. 2) Conocimiento de la actividad que describe una meta. 3) Conocimiento del tiempo relacionado con los cambios dinámicos. 4) Conocimiento sobre las relaciones con los ítems. Por ejemplo, relaciones dentro de un grupo de usuarios. 5) Conocimiento sobre la ubicación de usuario y/o ítem. Esta ubicación puede ser geográfica o virtual (dirección IP).

Cocare es un ejemplo para demostrar con un sistema de recomendación consciente del contexto que la ontología puede modelar este tipo de recomendadores. OntoCocare facilita la comprensión de los tres (3) elementos de conocimiento de los recomendadores CARS: Usuario, ítem e información contextual. Concretamente, CoCARE utiliza perfiles personales para guardar el conocimiento del Usuario, los contenidos multimedia que representan el Ítem y la información asociada a la ubicación del usuario, clima, agenda, etc. Esta información representa Información Contextual. Por otro lado, OntoCocare relaciona la información anterior con los componentes de técnicas de recomendación para recomendadores clásicos y conscientes del contexto. Esta ontología también clasifica elementos en categorías fundamentales de la especialidad de actividad física en el área de salud definidas como: 1) por ejemplo, el estilo de vida, actividad física, dieta, metas personales igual a salud. 2) O Conocimiento de la ubicación, por ejemplo: ubicación interior, quién está con él / ella. 3) Las fuentes de conocimiento son sistema de posicionamiento global, comunicación de campo cercano. Y finalmente OntoCocare relaciona las categorías fundamentales de datos, su relevancia y variabilidad.

Como conclusión: esta ontología es de gran utilidad para trabajos futuros ya que 1) define y clasifica todos los elementos que forman parte de un sistema de recomendación contextuales CARS. 2) Filtra los componentes según los datos utilizados en el sistema de recomendación. 3) Asimismo, acepta la extensión de la ontología agregando más ontologías o más componentes en el sistema de recomendación. 4) Y finalmente, es una herramienta que puede ayudar a generar

explicaciones al diseñador del CARS. 5) Puede ayudar al desarrollador a comprender por qué se utiliza cada técnica de recomendación.

2.1.19. Conclusión Capítulo 2

En este capítulo se ha descrito el desarrollo de la metodología general para conceptualizar el dominio de salud y actividad física, por medio del modelado de usuario y contexto.

Se tiene como resultado el modelo que representa el conocimiento sobre los datos que se integran al dominio y la conceptualización de ellos a partir del conjunto de ontologías seleccionadas para OntoCARE. Obteniendo una representación semántica de los datos, de manera que se pueda discernir los conjuntos de clases que se consideran fundamentales en los sistemas de recomendaciones clásicos y contextuales. La descripción de estas estructuras está basada esencialmente en la información relacionada con salud específicamente actividad física, relacionando las 3 dimensiones de los datos de recomendadores User X Item X Context. Además se logró reflejar un vínculo que refleje el comportamiento de los conceptos mediante el uso de BFO, para que sea válido y coherente con los términos generales de conceptualización, además que se ha definido en un lenguaje formal y representado en un vocabulario explícito para que personas ajenas a la ontología puedan interpretar y entender la conceptualización en términos generales.

Otro punto significativo de este apartado, es la adaptación de la ontología para sistemas de recomendaciones a la ontología de alto nivel BFO, y enfatizando la parte de información contextual. De esta forma partiendo de las características esenciales de la vecindad de conceptos que determinan directamente el contexto al cual pertenecen y relacionadas con la salud. Este conocimiento contextual se puede usar para restringir el significado de la comunicación o interpretación del mismo. Producto de contar con la base de ontologías de más alto nivel al de la aplicación, esta ontología es flexible a ser adaptada para otra especialidad en el dominio de salud y a evolucionar iterativamente con el tiempo.

En este trabajo se ha desarrollado una ontología integrada de procesos y recursos que cumple con los objetivos planteados inicialmente para la tesis, de modelar el usuario y su contexto para la implementación de un sistema recomendador, a partir de un modelo ontológico que posibilita una interpretación compartida de los

datos/información utilizados en las técnicas de recomendación para garantizar la consistencia y precisión de las recomendaciones entregadas al usuario. Además, se planteó que esta propuesta ontológica pudiera particularizarse para ámbitos más concretos como el de Actividad física que se deriva del dominio de la salud. Para ello, el modelo ontológico debería integrar el dominio de aplicación, considerando de forma especial tanto el conjunto de datos y sus relaciones.

Finalmente, se definió una ontología integrada de dominio con la riqueza semántica y su implementación mediante el lenguaje OWL. El uso de otras ontologías como base para el desarrollo de esta ontología facilita su interoperabilidad semántica con ontologías de otros ámbitos y permite considerar varios fundamentos ontológicos para conceptualizar con fidelidad la realidad a representar.

Como trabajo futuro se propone, extender el rango de las características y datos más allá del dominio de actividad física, teniendo en cuenta otras dimensiones, como son el ámbito nutricional, el contexto en la dimensión multicultural y tradicional, otros dominios fuera del de salud, adaptación a los distintos sistemas de recomendaciones, etc.

3. Capítulo 3. Construcción de un sistema de Recomendaciones consciente del contexto para promoción de Actividad Física CoCARE.

3.1.1. Introducción Capítulo 3

En la sesión 1.2 en el escenario de motivación de esta tesis, se describe la necesidad de construir un sistema de recomendaciones consciente del contexto (Context Aware Recommender System CARS), para mejorar la experiencia del usuario al buscar recomendaciones de actividad física; con la variante que deben ser favorables para la condición de su salud, esto implica que el sistema debe conocer la condición física del usuario que está buscando los contenidos, algo con lo que actualmente no cuentan todos los buscadores en Internet. Además, el sistema de recomendaciones debe incrementar la adherencia de los usuarios a programas de promoción y prevención de salud de manera que él no termine abrumado con demasiadas recomendaciones.

Se propone un CARS, porque permite realizar recomendaciones personalizadas basadas tanto en las características del usuario como las características de los Ítems (contenidos multimedia seleccionados por expertos en el área de salud) y su contexto o entorno. Estos sistemas entregan de forma natural, rápida y fácil los contenidos de actividad física que el usuario requiere, desea y puede realizar en el momento donde se encuentre y con quien se encuentre. Así se incrementará la adherencia a los programas de actividad física sugeridos por expertos en el área de salud.

El sistema que se propone en esta tesis es llamado CoCARE (ver Figura 19). Se compone de una ontología que organiza los datos de usuario y su contexto que será el insumo de la Query (consulta) que entra al recomendador híbrido, pasando los datos por varios filtrados (basado en contenido, basado en conocimiento y colaborativo) usando diferentes técnicas de recomendación (similaridad, clustering, vecinos cercanos KNN y ranking), para posteriormente entregar al usuario una lista de resultados favorables para su necesidad e interés. Adicionalmente el sistema cuenta con un componente de seguimiento continuo, que se divide en evaluación de culminación de tareas (verificar que el usuario vio el video e hizo actividad física mediante la retroalimentación del sistema y los dispositivos wearables como acelerómetros). Por otro lado la satisfacción de las recomendaciones al valorarlas e indicar sus favoritas y por último con el seguimiento de su condición física al actualizar los datos del sistema por parte del usuario y el experto en salud que le evalúa.

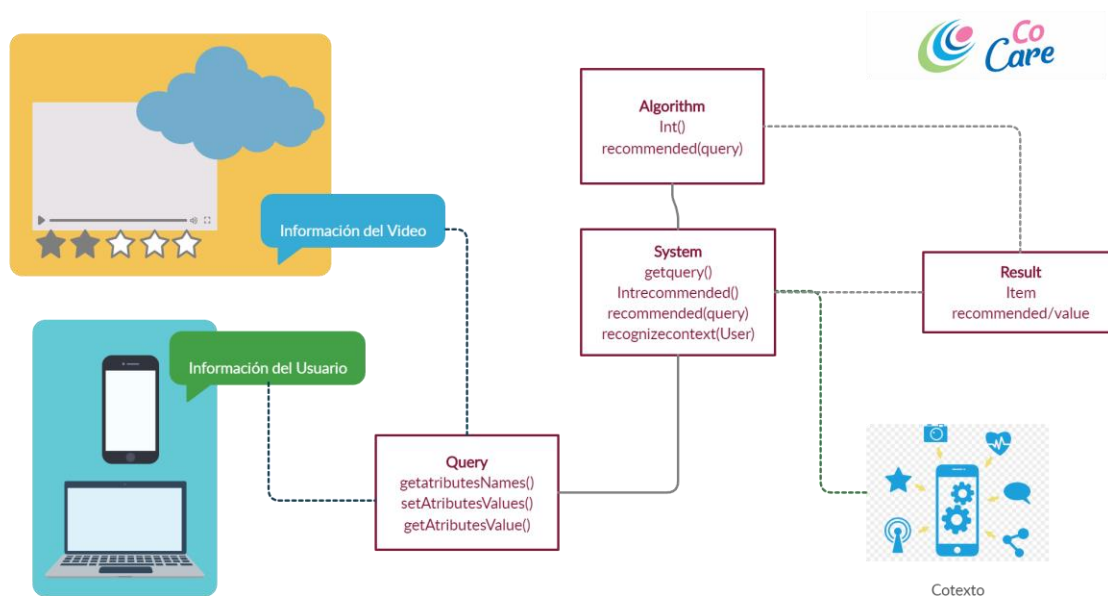


Figura 19. Diagrama general Cocare

(Fuente: elaboración propia)

En este capítulo se dará respuesta a las siguientes preguntas:

1. ¿Qué componentes tienen los sistemas de recomendaciones?
2. ¿Qué tipo de recomendadores clásicos y contextuales son eficientes para este tipo de sistemas?
3. ¿Cuáles técnicas de recomendación son más adecuadas para la implementación de estos sistemas de recomendaciones contextuales?
4. ¿Cuál es la arquitectura más adecuada para el desarrollo software de este tipo de sistemas?
5. ¿Cómo implementar un sistema propuesto en esta tesis?

En este capítulo se hace un breve resumen del concepto, componentes y diferentes tipos de sistemas de recomendaciones que existen para el dominio de la salud y específicamente actividad física, así como los diferentes enfoques que pueden utilizarse para implementar CARS (filtrado colaborativo, filtrado basado en contenido, filtrado basado en conocimiento o híbrido). Para esta tesis, resulta de especial interés explicar y hacer múltiples pruebas de diferentes tipos y técnicas de recomendación soportadas en algoritmos de inteligencia artificial, evaluando sus comportamientos y

eficiencia al momento de realizar las recomendaciones con base en los datos obtenidos del usuario y su contexto como de los ítems.

Por otro lado, se describen los criterios de selección de los algoritmos a usar, la arquitectura, el diseño de la interfaz de usuario, los componentes del software desarrollado y como se implementó el sistema Cocare.

3.1.2. Sistemas de recomendaciones

RS, son agentes de software que suscitan los intereses o preferencias de usuarios individuales para productos, ya sea explícita o implícitamente, y hacen recomendaciones en consecuencia.

El objetivo de un RS es generar recomendaciones significativas de los ítems adecuados para cada usuario según sus intereses.

3.1.2.1. Recomendadores Clásicos Vs Contextuales

Se tienen dos tipos de sistemas de recomendaciones clásicos y contextuales, esto depende del tipo de datos que alimentan el sistema para realizar la recomendación [73]. El clásico se basa en la bidimensionalidad es decir; una matriz de factorización $R: \text{Usuario} \times \text{Ítem}$ a un espacio. El contextual es multidimensional $R: \text{Usuario} \times \text{Ítem} \times \text{Contexto}$, donde el contexto puede estar conformado por una o más variables dinámicas (cambian en el tiempo). Matemáticamente los CARS manejan algoritmos más complejos que los de los sistemas de recomendación clásicos, ya que adoptan mecanismos que permiten incluir variables del contexto para hacer las recomendaciones.

En [140] se presenta un sistema de recomendaciones que además de la información de los usuarios y de los ítems, usa información contextual como datos de entrada para recomendar. Dicha inclusión de información contextual en los sistemas de recomendaciones se ha convertido en un tema importante de investigación en los últimos años [83], [141]. También se ha venido investigando en la forma como el contexto puede influenciar las decisiones de los usuarios. Por otro lado, este tipo de sistemas han sido implementados para la recomendación en dominios de turismo, educación, música y videos [23]. Los trabajos de investigación relacionados con sistemas de recomendaciones conscientes del contexto han aumentado los últimos años, ya que los investigadores han encontrado una gran ventaja el incluir información contextual dentro de los sistemas de recomendaciones clásicos.

Esta tesis contempla un sistema de recomendaciones consciente del contexto, para lo cual se hace necesario usar una matriz multidimensional es decir que los cálculos matemáticos y las técnicas de recomendación a usar deben ser adaptadas a ello. En [141], se mencionan diferentes formas de trabajar con las matriz factorial bidimensional y multidimensional.

Existen diferentes formas de gestionar datos de contexto, una forma es regresar a una matriz bidimensional aplicando un proceso de reducción de dimensionalidad donde básicamente se establece un valor para la variable contextual y se selecciona la matriz de factorización bidimensional que cumpla con dicho valor de contexto. Luego de la reducción de dimensionalidad es posible trabajar con SR clásicos. Trabajos como [24], [142] presentan distintas opciones para efectuar este proceso, a través de tres posibilidades: 1) hacer un pre-filtro: tal cual como se había considerado en la sesión 1.6.3.2; 2) hacer un post-filtro: en este caso primero se trabaja con todos los datos del dataset (Usuario X Ítem) sin considerar la información de contexto y al resultado aplicarle una reducción de dimensionalidad y; 3) incluir la información de contexto directamente en el modelo del SR.

En [143] se sostiene que las dos aproximaciones usando un prefiltro o postfiltro en los SR contextuales para un dataset específico, son buenos dependiendo de los datos que se están tomando del usuario y de los ítems, además de la forma como el recomendador recibe y almacena los datos. Para esta tesis se probaron varias técnicas y mecanismos que se discuten en el capítulo 4.

3.1.3. Técnicas de recomendaciones

En la literatura se encuentra una gran variedad de algoritmos de recomendación que se basan en diferentes principios y técnicas [42], [73], [144] para la generación de recomendaciones. Todos parten de los mismos puntos y tienen el mismo objetivo, realizar las recomendaciones, en el uso de la información disponible sobre las preferencias de los usuarios, de su interacción con el recomendador y/o de los productos. En [51] se mencionan cuatro (4) técnicas de recomendación: los basados en filtrado colaborativo, que son aquellos que utilizan valoraciones asociadas a los productos dadas por el propio usuario y/o por otros usuarios; los basados en contenido, que son aquellos que realizan la recomendación al usuario en base a la descripción de los productos; y los basados en conocimiento, que son aquellos que utilizan toda la información disponible sobre el usuario, sobre los productos y sobre el dominio de recomendación para efectuar las recomendaciones. Y la combinación de diferentes

estrategias de recomendación es una técnica habitual que da lugar a los sistemas de recomendación híbridos.

3.1.4. Filtrado Colaborativo

Esta técnica es una de las más empleadas en los sistemas de recomendadores. Se caracteriza porque en la recomendación a un usuario se utiliza conocimiento sobre otros usuarios, se entiende que si dos usuarios han compartido algunos de sus intereses en el pasado tendrán gustos similares en el futuro. Este tipo de filtrado empareja usuarios con preferencias similares o productos con similares patrones de valoración por parte de los usuarios [42]. Con esta técnica se buscan predecir un producto para un usuario determinado de acuerdo a las valoraciones que han dado para dicho producto otros usuarios con preferencias similares. Estas técnicas tienen la propiedad de que no hay descripciones de los productos, simplemente aprovechan la información acerca de las valoraciones anteriores.

En [144] se mencionan 2 tipos de estrategia para este tipo de recomendadores: vecinos cercanos y modelos de recomendaciones.

- **Basados en vecinos cercanos:** Se basan directamente en los datos observados, sobre los que aplican medidas de similitud, ya sea entre usuarios o entre ítems, a partir de las cuales se calculan predicciones de ratings. También infieren preferencias de un usuario basadas en las de usuarios (vecinos) similares, o bien infieren preferencias por ítems similares a los que se ha observado que el usuario prefiere, donde en todos los casos la similitud se mide en términos de la interacción entre usuarios e ítems.

Las estrategias basadas en vecinos consisten en realizar predicciones sobre la valoración de un producto P para un usuario U a partir de las valoraciones que le han dado a P los vecinos de U. Se han encontrado algunos problemas con esta estrategia es tener un grupo de usuarios vecinos, ya que para ser similares deben haber valorado los mismos productos en sus perfiles y asignado valoraciones parecidas.

- **Basados en modelo:** mediante datos de prueba (dataset), el algoritmo genera una representación propia de los datos conocido como “modelo” así puede hacer recomendaciones más precisas a usuarios parecidos al modelo.

Las ventajas del filtrado colaborativo son principalmente dos: buenos niveles de acierto (en términos de error de predicción), así como de novedad y de diversidad; y puede recomendar ítems de los que no se tenga ninguna descripción, sino sólo ratings de usuarios. Sin embargo, tiene la limitación del arranque en frío (cold start), es decir, tiene problemas para recomendar a usuarios poco activos o ítems poco conocidos.

3.1.5. Filtrado basado en contenidos

Este tipo de estrategia realiza la recomendación con base en la descripción y/o el contenido de los productos que va a recomendar. Se usan las características de los productos (ítem) disponibles y las valoraciones recibidas por un determinado usuario. Los diferentes productos se comparan con los productos que valoró positivamente el usuario y se recomiendan los ítem con mayor similitud. Con esta denominación se suele hacer referencia a algoritmos que generan recomendaciones mediante la comparación del contenido que describe cada ítem y el contenido que le interesa al usuario objetivo [73].

Frente al filtrado colaborativo, los métodos basados en contenido pueden recomendar ítems nuevos o poco conocidos, aunque tienen en general la misma dificultad que el filtrado colaborativo para usuarios con poca actividad, ya que no se conoce lo suficiente sobre su perfil. La principal limitación de la recomendación basada en contenido es que, recomendando ítems parecidos al perfil del usuario, se puede producir un cierto efecto de “encasillamiento” para éste, con poca novedad y diversidad en la recomendación.

Tiene una gran ventaja y es que permite realizar recomendación del arranque en frío (cold start) cuando se considera un perfil de usuario que permite relacionar con el ítem a recomendar.

Los sistemas basados en contenido tiene una desventaja, requieren que el usuario haya valorado un número mínimo de productos para poder construir su perfil de usuario y así realizar las recomendaciones adecuadas a su proceso de búsqueda de nuevos productos. En ocasiones no son aplicables, porque no disponemos de las valoraciones suficientes o bien porque no tenemos un conocimiento profundo de los usuarios.

3.1.6. Filtrado basado en conocimiento

Los sistemas basados en conocimiento soportan una representación explícita del conocimiento de un dominio específico y lo interpretan a través de técnicas de

razonamiento, para proporcionar un comportamiento de alto nivel a determinadas situaciones. Estos sistemas realizan recomendaciones partiendo del conocimiento que proporciona el usuario y los ítems a recomendar, razonando acerca de cuáles de éstos cumplen con los requisitos o necesidades de los usuarios [105][144].

Los recomendadores basados en conocimiento, utilizan toda la información disponible sobre las características del usuario, de los productos y el conocimiento del dominio para efectuar las recomendaciones. Este conocimiento permite al sistema de recomendación razonar e interpretar de forma flexible y contextualizada.

El incluir conocimiento adicional en los recomendadores ayuda a los sistemas en la tarea de aprender perfiles de usuarios para personalizar sus recomendaciones. Este conocimiento también contribuye a la solución de problemas de los otros enfoques de los sistemas de recomendaciones vistos anteriormente, como el arranque en frío o la dispersión de datos, ya que este conocimiento adicional permite el razonamiento y la inferencia de información a partir de la existente.

Según [145] los recomendadores basados en conocimiento se dividen en dos (2) tipos basados en casos y basados en restricciones.

Ambas técnicas se diferencian en: basados en casos se centran en recuperar ítem similares a partir de distintas métricas de similitud. Por su parte las aproximaciones basadas en restricciones hacen uso de un conjunto de reglas de recomendación previamente definidas y el conjunto de productos recuperados se determina a partir de aquellos productos que cumplen las reglas de la recomendación.

- **Basados en casos:** utiliza una aproximación basada en consulta (query) en la que el usuario especifica sus requisitos, intereses y/o características. Luego el sistema mediante métricas de similitud compara con los casos que están almacenados en el sistema y con base en ello recomienda el de mayor similitud.
- **Basados en restricciones:** utiliza un perfil de usuario que indica cuáles son sus requisitos, las características de los productos y un conjunto de restricciones que indican qué productos pueden ser recomendados según el contexto, para generar las recomendaciones. Cada una de las restricciones es un filtro para el sistema, se le solicitan al usuario mediante preguntas o formularios. Estos sistemas se basan en un conjunto de reglas definidas para hacer las recomendaciones y en el uso de estas reglas para determinar los productos a recomendar (que serán aquellos que cumplan las reglas).

Al igual que las técnicas anteriores, la recomendación basada en conocimiento también presenta limitaciones: en primer lugar adquirir el conocimiento lo más completo posible. La sobre especialización en las recomendaciones, tienen el peligro de ser muy similares entre sí. El problema del conjunto vacío para los recomendadores basados en conocimiento que utilizan un modelo basado en restricciones. En este caso el sistema debería ayudar al usuario a reformular su consulta o proponer una recomendación que cumple una parte de las restricciones.

3.1.7. Híbrido

Con el objetivo de mejorar la recomendación y cubrir las debilidades de los anteriores casos, han surgido enfoques de sistemas de recomendaciones híbridos, que combinan los algoritmos de filtrado colaborativo con los basados en contenido o de conocimiento [141].

Hay múltiples formas de realizar la combinación entre las diferentes familias, entre las que destacan las siguientes:

- Monolítico (favoreciendo ciertas características): Se realiza una fase de pre-procesamiento para combinar el contenido de los ítems y sus correspondientes ratings (mediante pesos), y a partir de estos nuevos datos se ejecuta un único recomendador para generar el ranking de la recomendación.
- Diseño en conjunto. Se aplican diferentes algoritmos de recomendación sobre una única entrada de datos (input) para generar una única recomendación (output) más robusta. Por ejemplo, se pueden combinar los outputs obtenidos de un recomendador de filtrado colaborativo y de un recomendador basado en contenido para obtener una única lista de recomendación. Existen dos tipos de diseños dentro de este tipo. Uno es el diseño en paralelo, que combina todos los resultados obtenidos de aplicar cada sistema de recomendación sobre el mismo input para obtener un único output (Figura 20). El otro es el diseño secuencial que lo que hace es aplicar un sistema recomendador sobre un input y utilizar ese output como input del siguiente sistema recomendador, y así sucesivamente, hasta aplicar todos los sistemas recomendadores y por último combinar todos los outputs obtenidos en un único output (Figura 21).

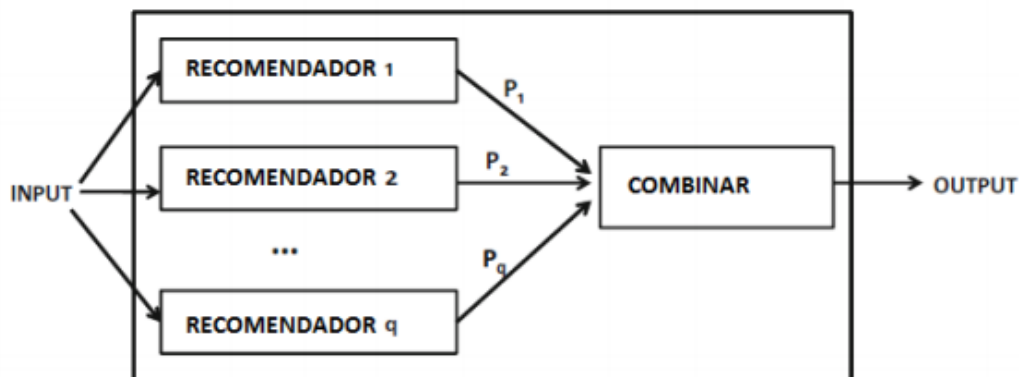


Figura 20. Diseño paralelo de un recomendador híbrido

(Fuente:[146])

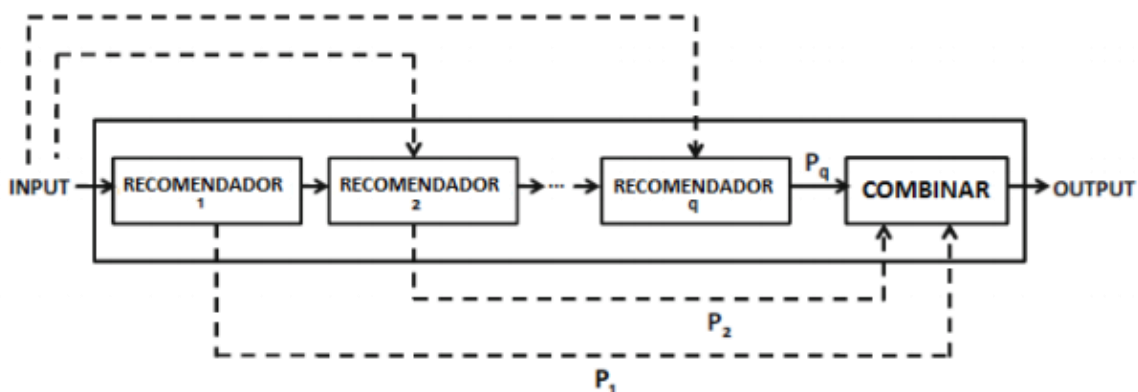


Figura 21. Diseño secuencial del recomendador híbrido

(Fuente:[146])

- Sistemas mezclados. Se utilizan diferentes algoritmos de recomendación sobre un único input, como en el caso del diseño en conjunto, pero se obtienen varios outputs.

Dentro de estos tres tipos de diseños, existen siete técnicas diferentes para combinar estrategias de recomendación [146], [147] (ver Figura 22):

- Ponderación: las valoraciones otorgadas por los diferentes tipos de recomendadores se agregan a través de algún tipo de esquema. El producto

con mayor valoración será el que se recomiende al usuario. Cada recomendador puede tener diferente peso en la valoración.

- Cascada: se utiliza un recomendador sobre el conjunto inicial, obteniendo un nuevo conjunto. A partir de éste, se aplica el otro recomendador y así sucesivamente hasta llegar al resultado final.
- Conmutación: cuando se cumplen ciertas condiciones, se aplica un recomendador, y si no, el resto de métodos o recomendadores.
- Mixto: el resultado obtenido es un conjunto de los resultados obtenidos con todas las técnicas de recomendación usadas.
- Combinación de características: los datos utilizados son la unión de todos los datos que utilizan todos los sistemas. Después, se aplica un único algoritmo de recomendación sobre ese conjunto.
- Incorporación de características: uno de los métodos genera una recomendación, más una característica nueva (por ej. productos relacionados) para el producto, que va a ser integrada como una nueva característica para el resto de estrategias de recomendación.

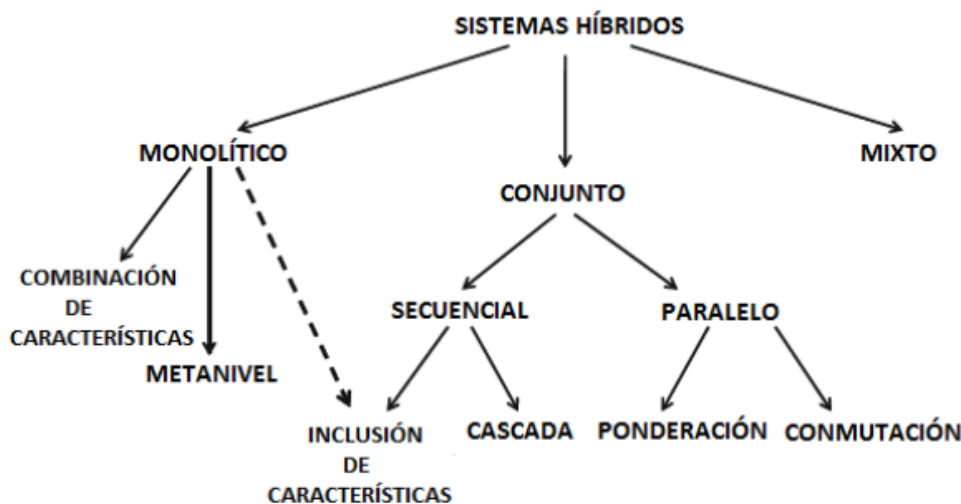


Figura 22. Clasificación de sistemas híbridos y sus técnicas

(Fuente:[146])

Las soluciones híbridas permiten, por ejemplo, mitigar el problema del arranque en frío propio del filtrado colaborativo, o la recomendación de ítems sin descripción, propio de los algoritmos basados en contenido, también solucionan la sobrespecialización y conjunto vacío de los basados en conocimiento. Esto gracias a que unos algoritmos respaldan las debilidades de los otros.

Este tipo de enfoque es el más adecuado para el caso de sistemas conscientes del contexto, ya que facilita las técnicas de filtrado (pre y pos) además genera alternativas a los problemas de recomendación de arranque en frío o en caso de no contar con suficiente información contextual y se genere un conjunto vacío. Por otro lado, permite la integración de varios tipos de algoritmos según la combinación que se elija ayudando la precisión de la recomendación.

3.1.8. Adaptación de técnicas de recomendación para la inclusión de contexto

Tabla 6. Matriz de factorización

	Item1	Item2	Item3	Item4	Item5
Gineth	5	3	4	4	?
User1	3	1	2	3	3
User2	4	3	4	3	5
User3	3	3	1	5	4
User4	1	5	5	2	1

Un recomendador antes de entregar un resultados debe predecir las preferencias del usuario. Como se ha mencionado anteriormente, los recomendadores clásicos contemplan una matriz bi-dimensional User X Item, dependiendo del filtrado relaciona entre sí las calificaciones o nivel de preferencia que cada usuario ha expresado por los ítems.

Particularmente, el filtrado colaborativo realiza la tarea de predicción usando la información o ratings de otros usuarios del sistema, similares al usuario para el cual se desea recomendar. Esta información es traducida a una matriz de factorización como la mostrada en la Tabla 6. Por ejemplo, dado un "usuario activo" (Gineth) y un elemento que Gineth todavía no ha visto, el objetivo es estimar la calificación de Gineth para este ítem. Para esta tarea se debe encontrar un conjunto de usuarios (pares) a quienes les gustaron los mismos elementos que Gineth en el pasado y que hayan calificado el Ítem 5. Luego se promedia sus calificaciones para predecir si a Gineth le gustará el ítem 5.

Un recomendador contextual requiere agregar una nueva variable al sistema. Esto es pasar de una matriz bi-dimensional a multidimensional, donde además de tener en cuenta User X ítem, se consideran nuevas variables que se convierten en nuevas dimensiones dentro de la matriz de factorización (ver Figura 23). Por ejemplo en

el caso de la Figura 23, se considera User X Item X Time y se muestra como la recomendación R debe considerar los tres valores para calificar un ítem a recomendar.

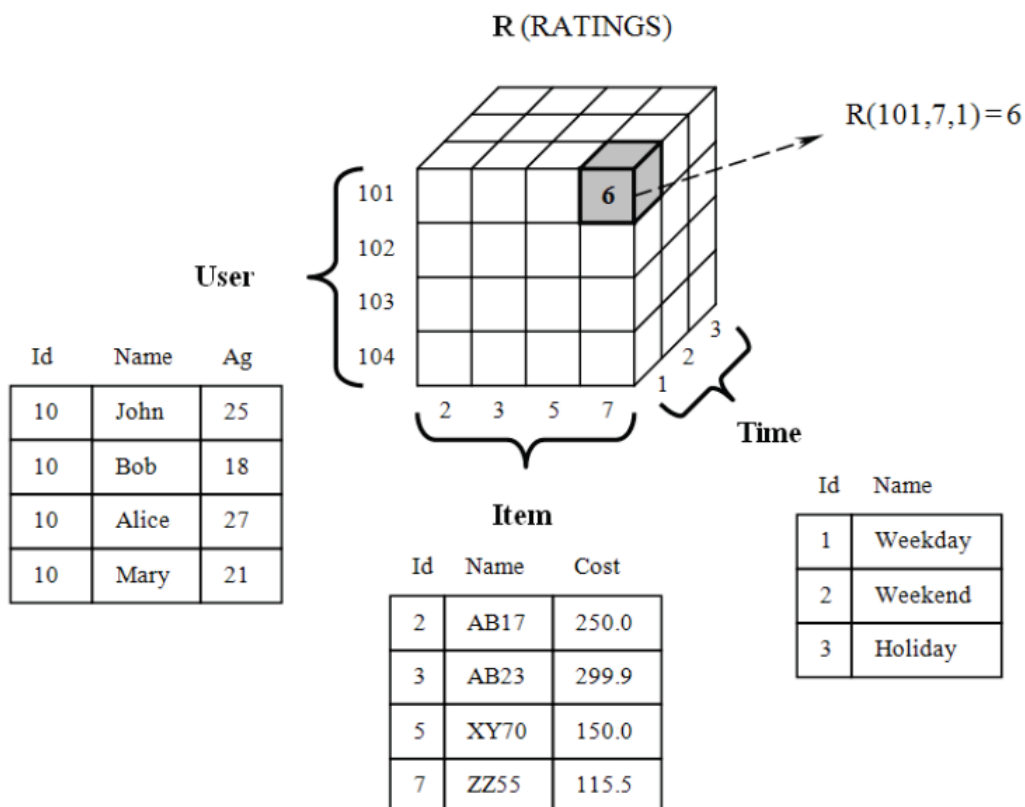


Figura 23. Matriz de factorización contextual

(Fuente [51])

En [51] se muestran cómo reducir la matriz 3D a 2D, para así poder ser tratado como un recomendador clásico. Para ello se proponen tres formas: pre-filtrado, pos-filtrado o basada en modelo (ver Figura 24).

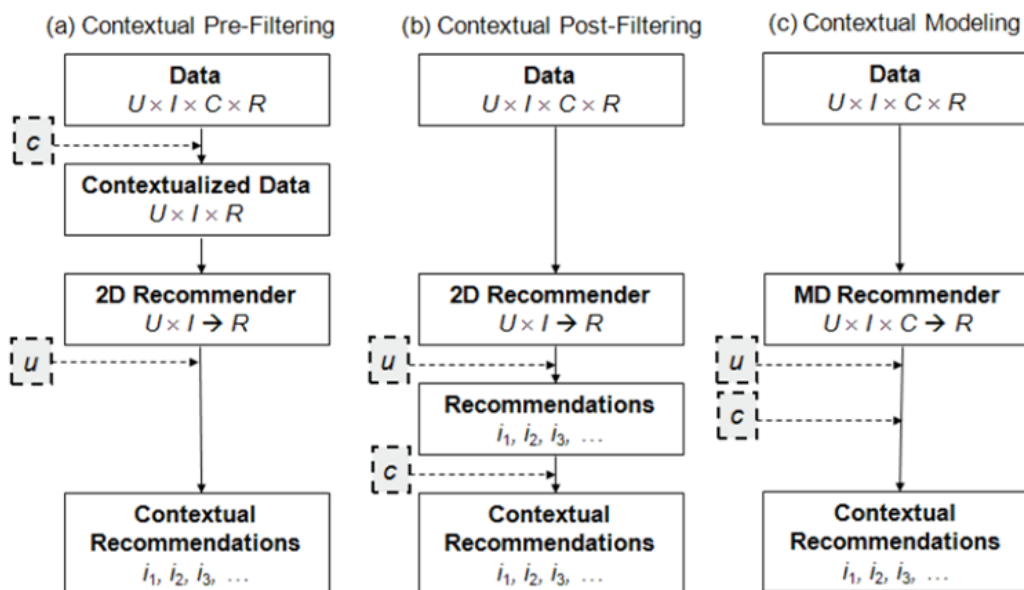


Figura 24. Técnicas de Reducción de matriz de factorización contextual

(Fuente [51])

- **Pre-filtrado:** filtrado previo al dataset general y se obtiene uno nuevo que será el utilizado para hacer la recomendación.
- **Pos-filtrado:** primero hace una recomendación con base en los datos de Ítem X User y posteriormente ese resultado se filtra con las nuevas variables.
- **Basado en Modelo:** básicamente requiere modificar la ecuación de los recomendadores clásicos y se calcula de predicción y la reducción se hace en el momento de hacer la recomendación.

3.1.1. Métricas de similitud

La similitud se define como la medida de cercanía entre objetos que podría ser elementos para hacer la recomendación con base en perfiles de usuario. Las métricas

de similitud se utilizan en métodos de clasificación y técnicas de agrupación [73]. Algunas de las medidas de similitud conocidas que se usarán en esta tesis son:

- **Distancia Euclidiana:** Esta es la distancia entre dos puntos u objetos, x y y , con i dimensiones. Esta es siempre mayor o igual que cero. La medición sería cero para puntos idénticos y alta para puntos que muestran poca similitud, la Ecuación 1, es el ejemplo más simple y más común de un medida de distancia, donde (x, y) son objetos, $x_i, y_i: i^{th}$ atributos o componentes de cada objeto, n numero de dimensiones o atributos y d distancia entre objetos de datos.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Ecuación 1. Distancia Euclidiana

- **Manhattan / City Block Distance:** es la suma de diferencias absolutas entre i dimensiones de objetos de datos, que es similar al movimiento dentro de una ciudad donde las personas o los automóviles tienen para moverse por los edificios en lugar de pasar directamente. Esta distancia es siempre mayor o igual que cero. La medida sería cero para puntos idénticos y alto para los puntos que muestran poca similitud. En la Ecuación 2 (x, y) se representan los objetos, $x_i, y_i: i^{th}$ atributos o componentes de cada objeto, n es el número de dimensiones o atributos y d distancia entre objetos de datos.

$$d(x, y) = \sum_{i=1}^n |x_i - y_i|$$

Ecuación 2. Manhattan / City Block Distance

- **Similitud de coseno:** conocida como similitud basada en vectores, esta ecuación (Ecuación 3. Similitud de coseno) considera los objetos de datos como los vectores de un espacio n -dimensional y define su similitud como el coseno del ángulo que forman. Esta métrica se calcula como el cociente entre el producto punto vectorial y el producto de la normal de los datos. La medición sería cero para puntos idénticos y alta para puntos que muestran poca similitud.

$$\cos(x, y) = \frac{\vec{x}_i \cdot \vec{y}_i}{\|\vec{x}_i\|_2 * \|\vec{y}_i\|_2}$$

Ecuación 3. Similitud de coseno

3.1.2. Métricas de evaluación

La forma que se propone para determinar la efectividad de los recomendadores utilizados, es mediante el uso de tres métricas que relacionan los vídeos recomendados y las características del usuario, las cuales son utilizadas para evaluar la efectividad de las técnicas de recomendaciones que generan la recomendación final.

1. **Precisión:** Esta métrica determina el número de vídeos recomendados que han sido calificados por los usuarios como buenas recomendaciones sobre el total de vídeos recomendados. Responde a ¿cuántos les gustó realmente al usuario? de todos los elementos recomendados. Está dada por la Ecuación 4. Métrica de precisión, donde tp representa la cantidad de elementos recomendados para un usuario que le gustan y fp representa el total de elementos no recomendados para un usuario que gustan. A mayor precisión, mejores recomendaciones.

$$Precision = \frac{tp}{tp + fp}$$

Ecuación 4. Métrica de precisión

2. **Recall:** Responde a ¿Qué proporción de elementos que le gustan a un usuario en realidad fueron recomendados? Esta métrica es la relación entre la lista de vídeos que el recomendador genera y la lista de vídeos que el usuario anteriormente ha considerado de su gusto, dividiendo dicha relación entre el número de vídeos que le gustan al usuario.

En la Ecuación 5, tp representa la cantidad de elementos recomendados a un usuario que le gustan fn el total de elementos recomendados a un usuario que no le gustan. Cuanto mayor sea el valor de Recall, mejor son las recomendaciones.

$$Recall = \frac{tp}{tp + fn}$$

Ecuación 5. Métrica Recall

3. **F1 Score:** esta métrica utiliza las métricas anteriores, precisión y recall, y se calcula con la siguiente fórmula:

$$F1_{Score} = \frac{2 * Precisión * Recall}{Precisión + Recall}$$

Ecuación 6. Métrica F1 score

3.1.3. Implementación del sistema de recomendaciones contextual Cocare

3.1.4. Arquitectura Cocare

Se propone una arquitectura de implementación del sistema de recomendaciones contextual Cocare. Esta es una arquitectura de referencia para la promoción de la salud soportada en sistemas de recomendación contextual. En la Figura 25 se presenta una visión de los componentes principales de la arquitectura.

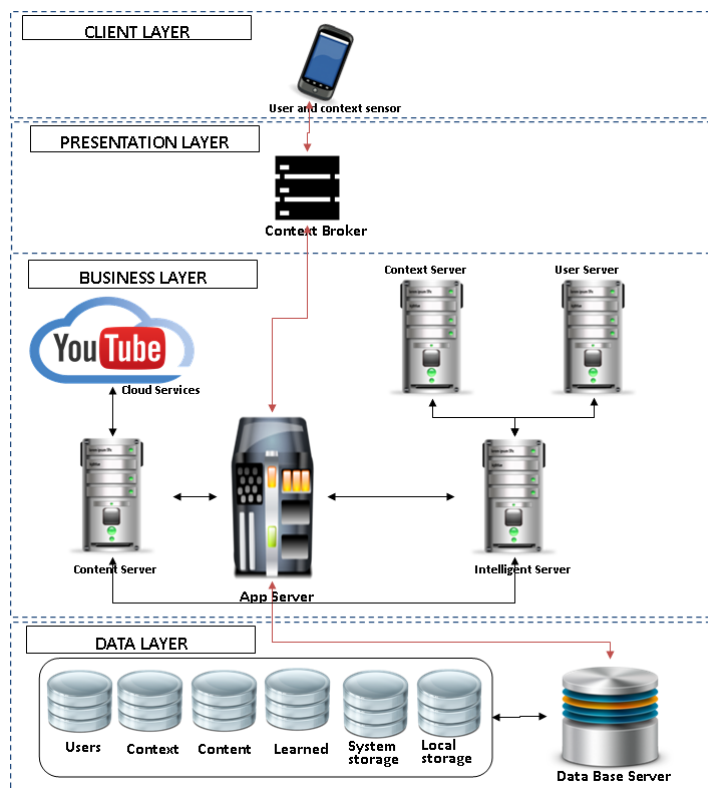


Figura 25. Arquitectura de CoCARE

(Fuente: elaboración propia)

- **Sensores de usuario y contexto:** Comprende el uso de tecnologías de ubicación para el despliegue en interiores y exteriores, utilizando diferentes tecnologías de detección y comunicación como NFC (Near Field Communication), Bluetooth Low Energy Beacons, entre otras. Se utiliza para la geolocalización en interiores, proporcionando la ubicación implícita del usuario (por ejemplo, cocina, sala de estar o dormitorio). El GPS (Sistemas de posicionamiento global) podría usarse para ubicaciones al aire libre (por ejemplo, lugar de trabajo, restaurantes, parques etc).
- **Context-Broker:** Módulo intermedio y de control, que gestiona la comunicación entre el cliente y las capas de presentación. En el prototipo implementado, el agente de contexto admite tres (3) tipos de comunicaciones: 1) NFC para monitorear ubicaciones específicas y la presencia del usuario allí. Requiere la disponibilidad de esa tecnología en dispositivos móviles. 2) GPS para monitorear la ubicación general. Este tipo de comunicación se proporciona para teléfonos, tabletas, computadoras portátiles y computadoras de escritorio. 3) La comunicación en la nube como el principal canal de comunicación, disponible para todos los dispositivos. Permite la sincronización de datos con la base de

datos a través de la capa del servidor de aplicaciones. También muestra el contenido multimedia recomendado.

- **Servidor de aplicaciones:** se da cuenta de la lógica empresarial del sistema y conecta la capa de presentación y la capa de base de datos. Además, actúa como intermediario para otros servidores y bases de datos.
- **Servicios en la nube:** este componente almacena grupos de contenido multimedia alojados en servidores en línea que pertenecen a organizaciones externas al proyecto, por ejemplo "Youtube". Se comunica con el servidor de contenido para facilitar los recursos multimedia asociados con el contenido multimedia que se recomienda al usuario.
- **Context Server:** su función es recopilar y organizar datos que han sido detectados con tecnologías de ubicación y almacenados en la base de datos de contexto, teniendo en cuenta los datos que son relevantes en el contexto del usuario de la base de datos. Estos datos se envían al componente del servidor inteligente.
- **Servidor inteligente:** la tarea de este componente es recibir datos del servidor de contexto, procesarlos, hacer inferencias y comunicarse con el servidor de contenido para recomendar información de acuerdo con el contexto físico y personal. Además, identifica qué técnica de recomendación utiliza el sistema de recomendación.
- **Servidor de contenido:** es un repositorio de contenido multimedia con metadatos etiquetados. También utiliza contenido del servidor, así como servicios de contenido en la nube, para organizarlo y redirigirlo al agente del servidor inteligente a fin de realizar las recomendaciones.
- **Servidor de base de datos:** este componente gestiona las bases de datos, realiza las operaciones CRUD (Crear, leer, actualizar, eliminar) y coordina la sincronización de los datos almacenados en la base de datos fuera de línea (información en la memoria del dispositivo móvil) con bases de datos generales. Incluye las seis bases de datos representadas en la Figura 2.

3.1.5. Descripción del sistema CoCARE

En esta tesis se implementó un sistema de recomendaciones consciente del contexto para la promoción de actividad física llamado "**CoCARE**" por las siglas "Co= contexto" "CARE= Cuidado de la salud". El sistema recomienda contenido multimedia sobre actividad física que han sido seleccionados previamente por expertos en el campo de la promoción de la salud. Este sistema utiliza un recomendador híbrido que

incorpora información de usuario, ítem y su contexto para adaptar la interfaz al estado actual del usuario.

El conocimiento del contexto explotado por CoCARE es la información de ubicación proporcionada, por ejemplo, por GPS, sensores de ubicación en interiores (NFC), amigos, fecha (día o temporada), horario diario del usuario y actividad del usuario (movimiento). Esta información se agrega al perfil o las preferencias del usuario, como los datos que el sistema aprende durante la interacción del usuario con el sistema (videos favoritos o no me gusta). También se considera la información social, como los mejores videos calificados por amigos.

El objetivo del sistema es ser fácilmente comprensible por cualquier persona y proporcionar recomendaciones personalizadas de una manera no intrusiva. Los datos de contexto se infieren en tiempo real, y las recomendaciones se mejoran dinámicamente a medida que el sistema aprende. Además, el sistema proporciona notificaciones (por ejemplo, el usuario recibe recordatorios).

3.1.5.1. Diseño CoCARE

Siguiendo la metodología de Diseño centrado en el usuario [115], se realizaron los diseños del logo, la interfaz de web y móvil, ya que es un sistema multiplataforma y cuenta con diseño adaptativo (responsive design) que permite su adaptación a diferentes dispositivos.

El logo representa el cuidado de la salud. Por medio de entrevistas y grupos focales se definió una paleta de colores que representan la salud y la actividad física. En la Figura 26 y Figura 27 se muestra el logo de CoCARE, el círculo rosado representa la persona y los demás semiovalos su contexto. Se eligió un poco ovalado dando dinámica al logo.



Figura 26. Logo CoCARE en forma de cuadrado
(Fuente: elaboración propia)



Figura 27. Logo CoCARE en forma rectangular
(Fuente: elaboración propia)

En la Figura 28 se muestran las funcionalidades del sistema y su apariencia, los recuadros rojos evidencian las funciones principales del sistema cuando está registrado el usuario. El ovalo azul de la parte superior izquierda muestra el registro de datos adicionales para que se complete el perfil de usuario. El recuadro morado de la parte superior derecha es para ver más videos. Un punto importante es el recuadro verde a la derecha del video, la calificación solo se puede hacer cuando el usuario ha visto más del 70% del video, garantizando que tenga criterio para decir su valoración.

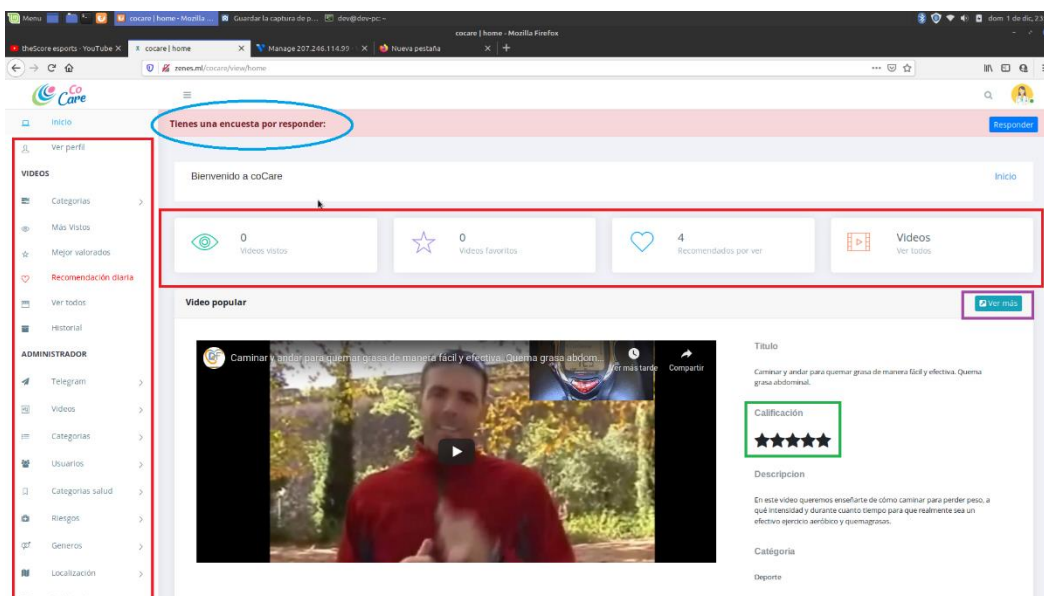


Figura 28. Sistema de Recomendaciones consciente del context CoCARE.
(Fuente: elaboración propia)

La ubicación de los iconos y las funciones fueron sugeridas por diferentes personas expertas en salud y con profesionales de desarrollo de software. Con sugerencias de un diseñador.



- Framework

El framework utilizado para este sistema fue Bootstrap (versión 4.1.3). Este framework de CSS, es muy utilizado en páginas web modernas, además de que es flexible y responsivo, por lo que su Implementación fue muy conveniente para este trabajo. También utilizamos JavaScript y AJAX, muy importantes para evitar sobrecargas en el sitio web. También se utilizó el plugin DataTables el cual facilita búsquedas, la gestión de registro de usuarios entre otras funcionalidades.

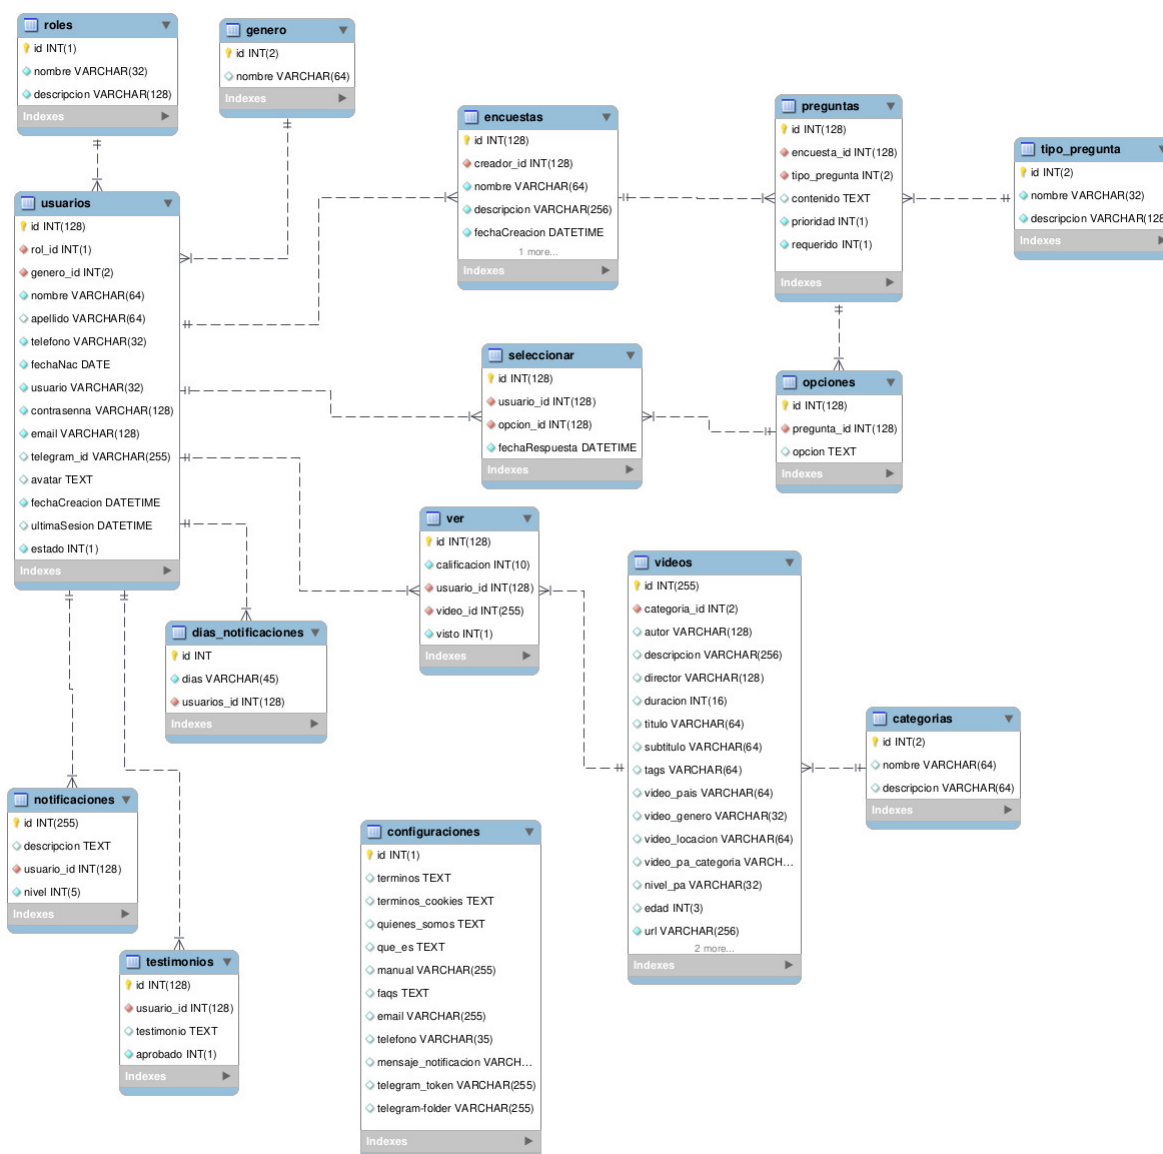


Figura 29. Relación de datos del Sistema

(Fuente: elaboración propia)

- Base de datos y relaciones

Principalmente se utilizó una base de datos relacional MySQL donde se crearon 16 tablas. Los usuarios podrán ver videos, modificar su perfil, y también tendrán que llenar un formulario el cual el administrador los crean. Los usuarios también tendrán el privilegio de actualizar sus respuestas del formulario. La base de datos tiene como nombre “bd_COCARE”, esta base de datos, se relaciona con la ontología planteada en la sesión 2.

3.1.1. Funciones de CoCARE

Las figuras Figura 31, Figura 32, Figura 33, Figura 34 muestran los casos de uso del sistema CoCARE relacionados con los diferentes roles que permite el sistema. Se cuenta con un Administrador, experto de salud, usuario e invitado. La secuencia de privilegios se describe en la Figura 30, lo que representa es que todo lo que hace el invitado lo puede hacer el usuario y otras funciones más, así mismo el experto en salud puede hacer lo mismo que el usuario y otras funciones y el administrador puede hacer todo y el CRUD.

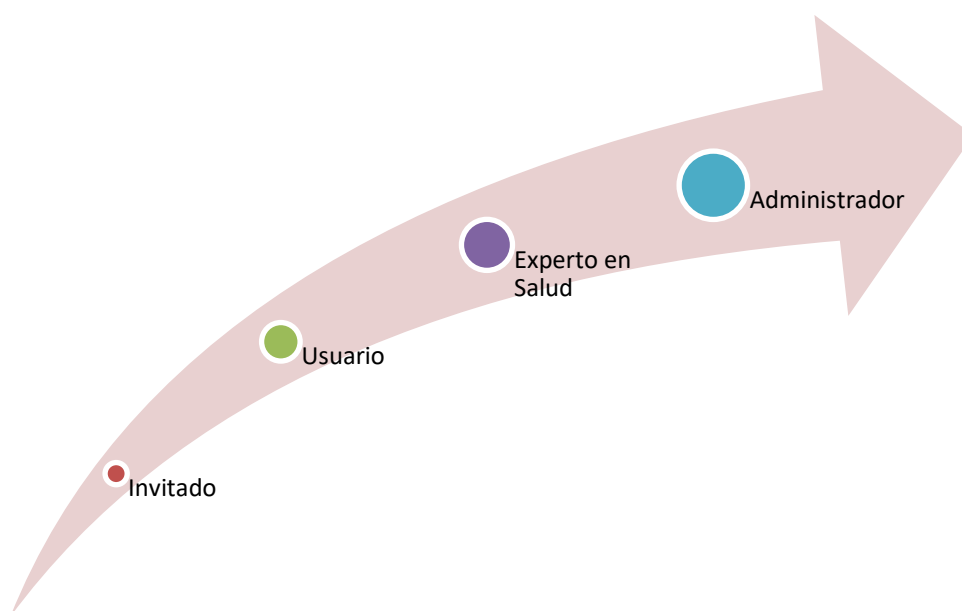


Figura 30. Secuencia de privilegios en el uso del Sistema CoCARE.

(Fuente: elaboración propia)

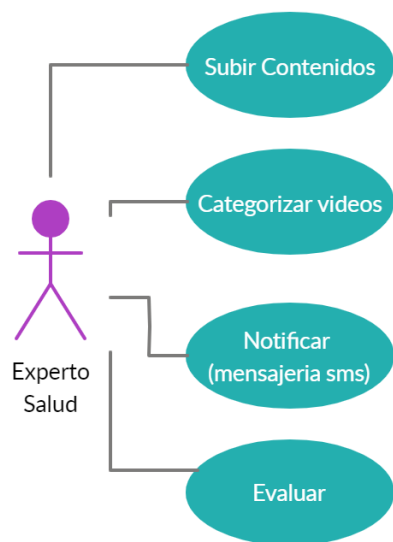


Figura 31. Casos de Uso Experto en salud
(Fuente: elaboración propia)

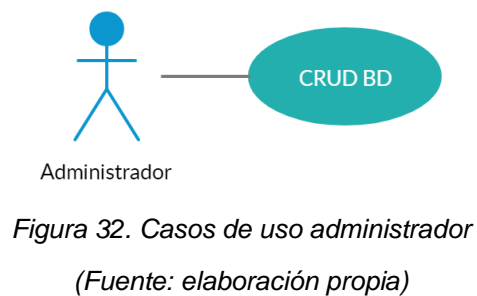


Figura 32. Casos de uso administrador
(Fuente: elaboración propia)

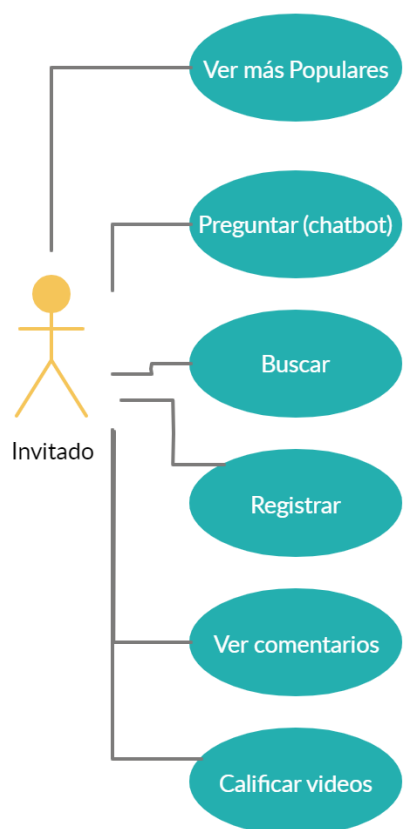


Figura 33. Casos de Uso Invitado
(Fuente: elaboración propia)

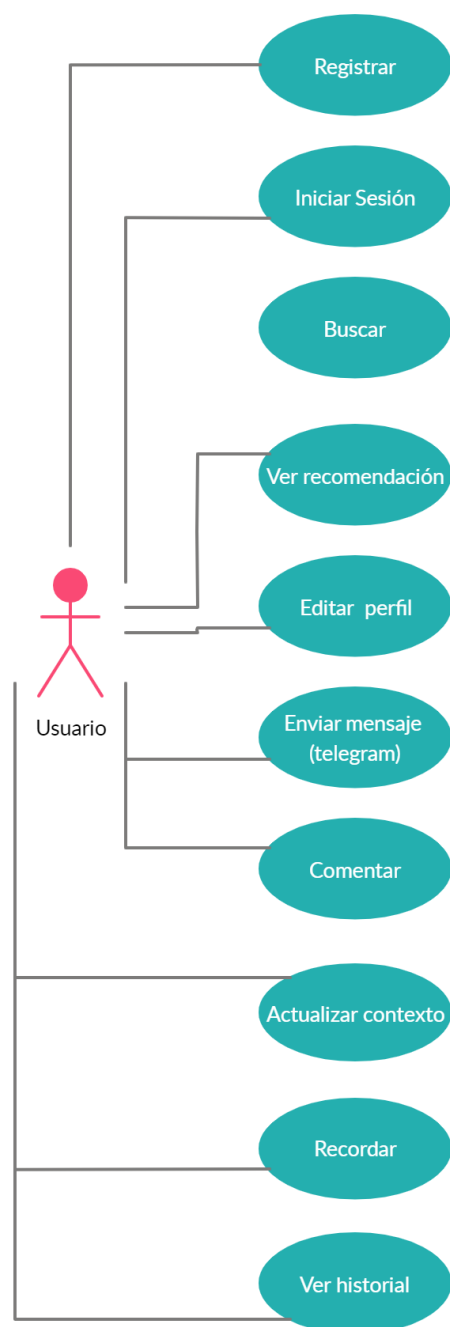


Figura 34. Casos de Uso Usuario
(Fuente: elaboración propia)

En el Anexo B se describe con más detalle el sistema. CoCARE está alojado en la URL <http://zenes.ml/cocare/> y el código en <https://github.com/mfcardenas/CoCareWeb>.

A continuación se describen las funciones relacionadas con el recomendador:

- **Registrar:** llenar formularios extensos hoy día no es conveniente para la usabilidad del sistema, por esta razón el usuario primero se registra con unos datos básicos, y a medida que él usa el sistema en cada inicio de sesión se le piden más datos haciendo que su perfil sea más completo (registrar datos adicionales).

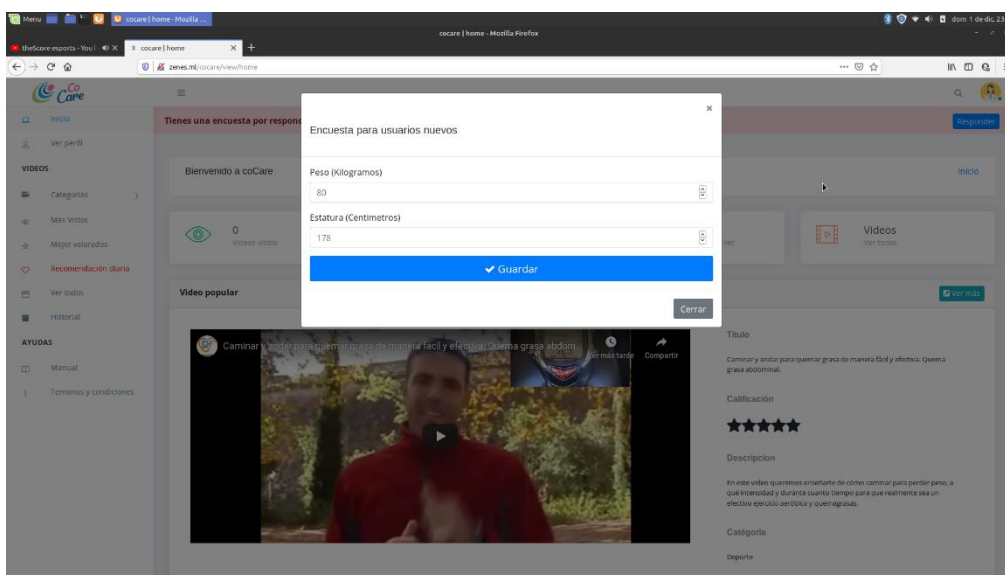


Figura 35. Registrar datos adicionales

(Fuente: elaboración propia)

- **Subir contenidos y categorizar.** El experto en salud puede subir el video de dos formas: desde un archivo de su almacenamiento interno de su dispositivo o desde la nube con una URL de Youtube. Posteriormente categoriza el video asignando los metadatos que se relacionan con la salud del usuario y la ontología OntoCARE. En la **¡Error! No se encuentra el origen de la referencia.** y Figura 36 se observa la función del administrador o del experto en salud como agregar videos y categorizarlos. Además como se toman los datos de youtube ellos traen unos metadatos básicos que se pueden modificar y ampliar en la plataforma. Los datos que se compararan en el recomendador con los datos del usuario. La siguiente imagen evidencia que solo con la url del video el experto guarda el video en la plataforma y se toman los datos.

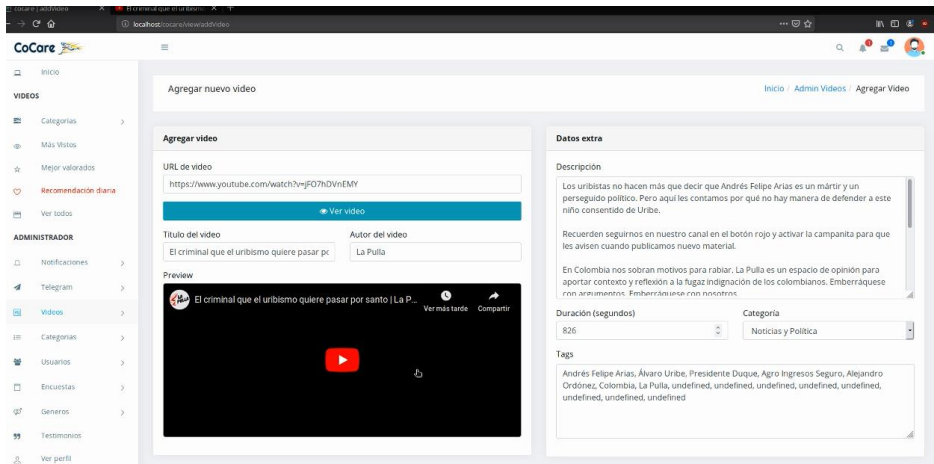


Figura 36. Vista de subir video
(Fuente: elaboración propia)

- **Ver Recomendaciones y ver más populares:** en los dos casos se muestra una lista de videos con base en los datos de entrada del usuario y el recomendador que se adapta a la necesidad ya sea un recomendador clásico si no cuenta con información contextual o contextual si tiene información del contexto.

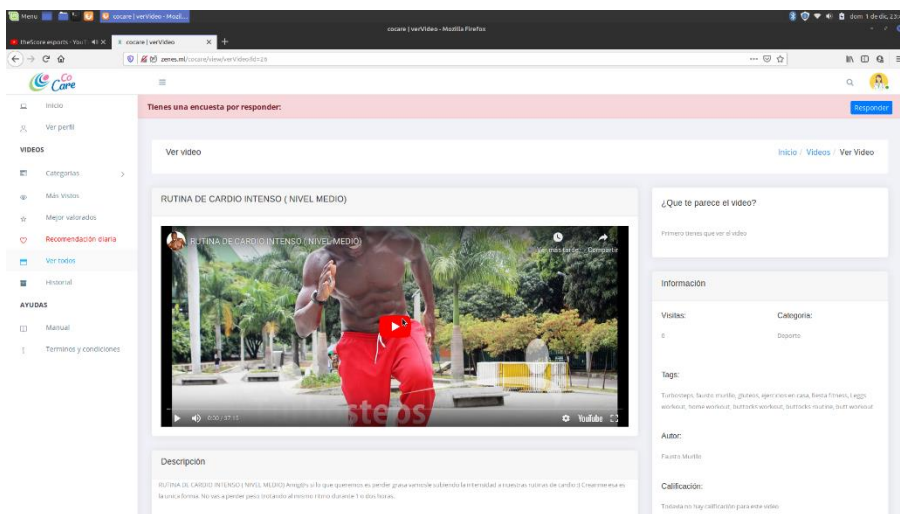


Figura 37. Ver recomendación
(Fuente: elaboración propia)

- **Buscador:** puede buscar videos por categorías o en sus favoritos.

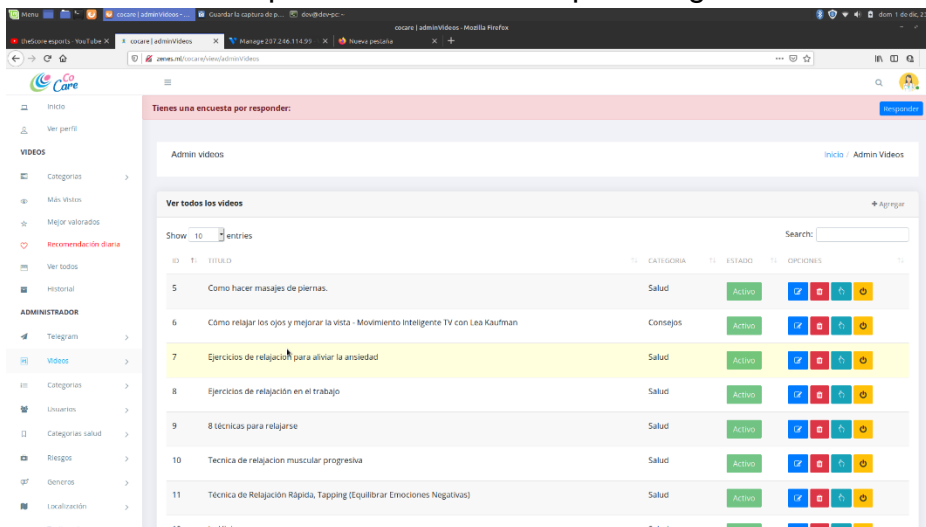


Figura 38. Buscador de videos por categoria

(Fuente: elaboración propia)

- **Notificaciones:** se le recuerda a los usuarios en sus horarios disponibles que recomendación debe realizar de acuerdo a sus necesidades.
 - Notificación Web (vía aplicación): notificar al usuario que es buen momento para continuar con el seguimiento diario.
 - Notificación Telegram: el usuario recibirá el mismo mensaje vía Telegram (individualmente).
 - Notificación Telegram Grupo: el grupo de usuarios recibirá mensajes de estímulo en el grupo de Telegram.
 - Email: enviar un email al usuario.
 - Mensajes sms: se le recuerda a los usuarios por medio de mensajería de texto a su celular por si no tiene datos que debe hacer algún tipo de actividad física y se le manda una sugerencia.
- **Comunicación por chat (telegram y chatbot):** se pueden comunicar con su experto en salud por medio de mensajes personales en el inbox.




Figura 39. Chatbot

(Fuente: elaboración propia)

- **Historial:** se le hace un seguimiento continuo de cuantas recomendaciones ha visto. Se aclara que el sistema verifica dos cosas: si vio más del 70% del video y si está moviéndose mediante un acelerómetro con el fin de verificar que la recomendación de actividad física se siguió.

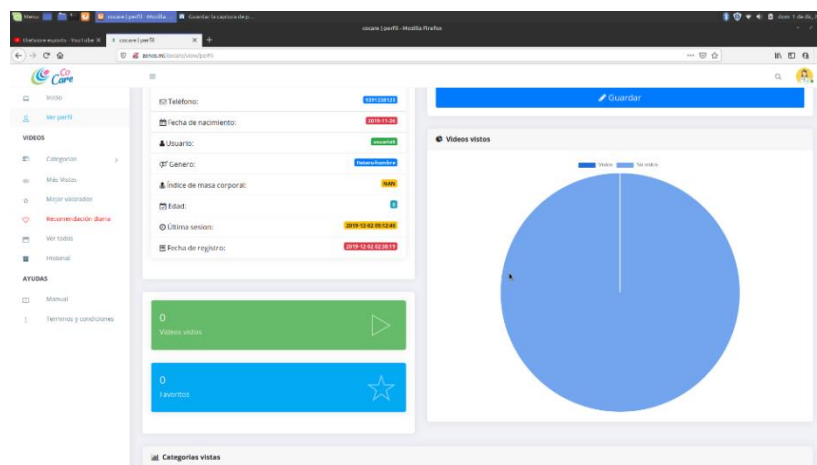


Figura 40. Historial CoCARE

(Fuente: elaboración propia)

- **Calificar:** El usuario podrá valorar el video solo si ha visto más del 70% de él, de lo contrario estará deshabilitada esta opción.

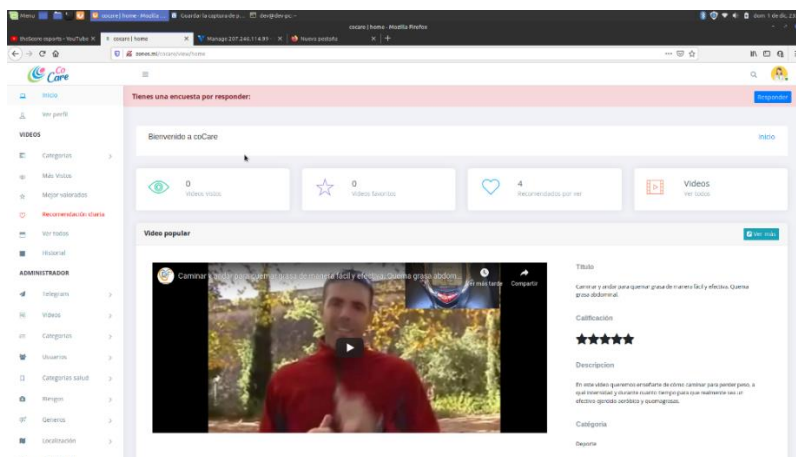


Figura 41. Calificar Video
(Fuente: elaboración propia)

3.1.2. Algoritmo Híbrido CoCARE

La Figura 19 mostraba los componentes básicos del sistema CoCare. A continuación, se describe en detalle los componentes del sistema con relación al proceso de recomendación.

- **Componente Query:** es la consulta del sistema de recomendaciones, este componente toma los datos del usuario, ítem o contexto, dependiendo del algoritmo que los requiera.
- **Componente Sistema:** se encarga de recibir los datos de la query, reorganizar y adaptar la información del usuario y su contexto para ser usada por el recomendador, esto con base en el tipo de recomendador y técnica de recomendación que se está requiriendo. Posteriormente se envía al componente algoritmo los datos U X I X C para ser procesados. Además, se encarga de procesar y almacenar las interacciones del usuario con el sistema, el seguimiento del usuario con respecto a los datos de ítem, contexto y a las actualizaciones de su condición física y sus datos de usuario y contexto, además de estar continuamente verificando los cambios en ellos.
- **Componente Algoritmo (estrategias de recomendación y medidas de similitud):** recibe los datos del sistema, que pasan a los algoritmos donde se

realizan los cálculos respectivos de acuerdo a la técnica de recomendación a aplicar, para posteriormente entrega un resultado que será una lista de datos que identifican las recomendaciones adecuadas para los usuarios.

- **Componente de resultados:** recibe los datos del recomendador y despliega las recomendaciones al usuario.

Para la implementación del sistema de recomendaciones consciente del contexto CoCARE se usó el enfoque descrito en la sección 4.2.3. En la Figura 42 se muestra las combinaciones del recomendador Híbrido contextual.

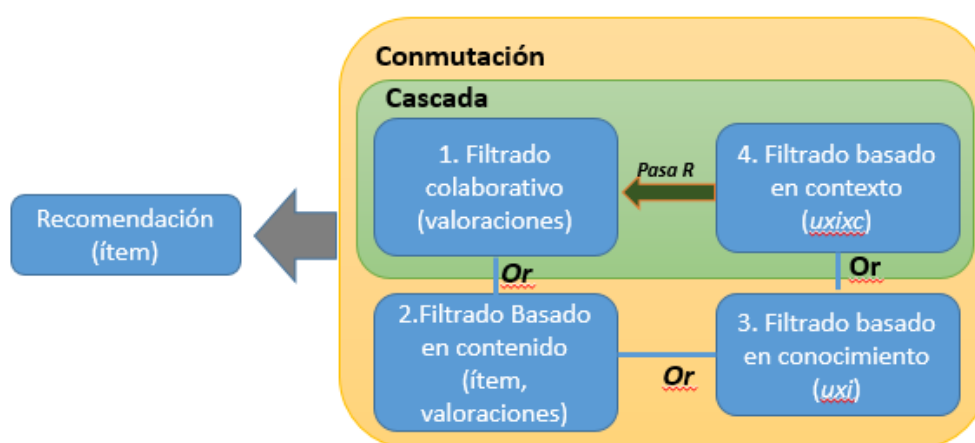


Figura 42. Combinación de estrategias de recomendación híbrida
(Fuente: elaboración propia)

Se cuenta con 4 tipos de recomendadores que se usaran en diferentes momentos dependiendo de la necesidad. CoCARE dependiendo de los datos de entrada con los que se cuenta.

Se cuenta con un recomendador basado en filtrado colaborativo, para lo cual se calcula la similitud entre cada par de ítems. Así se encuentra la similitud entre cada par de videos, para recomendar ítems similares que les gustaron a los usuarios en el pasado. Se toma la suma ponderada de las calificaciones de “ítem-vecinos”. La predicción está dada por:

$$P_{u,i} = \frac{\sum_N (s_{i,N} * R_{u,N})}{\sum_N (|s_{i,N}|)}$$

Ecuación 7. Ponderado de Item – item filtrado colaborativo

Luego se encuentra la similitud entre los elementos a través de la ecuación 8.

$$sim(i, j) = \cos(\vec{i}, \vec{j}) = \frac{\vec{i}, \vec{j}}{\|\vec{i}\|_2 * \|\vec{j}\|_2}$$

Ecuación 8. Similitud de elementos filtrado colaborativo

Con la similitud entre cada item y las calificaciones, se hacen predicciones y, con base a esas predicciones, se recomiendan videos similares.

Los otros tres enfoques de la técnica de similitud usan la distancia euclidiana descrita en la sesión 3.1.1. Se seleccionó esta medida de similitud después de las múltiples pruebas de recomendadores definidos en la sesión 4.

En esta tesis se concluye que los recomendadores pueden ser útiles o buenos, dependiendo de la necesidad y los datos de entrada con los que se cuente. El de contexto además del perfil básico, aprovecha la información de contexto para mejorar la recomendación, y acierta en su objetivo. Pero cada recomendador puede ser útil en determinados escenarios de la aplicación, dependiendo de los datos de entrada por ejemplo:

- **Usando información del ítem:** es útil para usuarios no registrados en una aplicación (invitados), porque solo necesitas la información base del perfil de usuario.
- **Usando información del usuario:** es útil cuando ya conoces algo más del usuario (Usuarios registrados), cuando ha puntuado un vídeo o cuando tienes más información de su perfil base.
- **Usando información contextual:** para todo usuario que utilice activamente la aplicación, personalizar constantemente la recomendación.

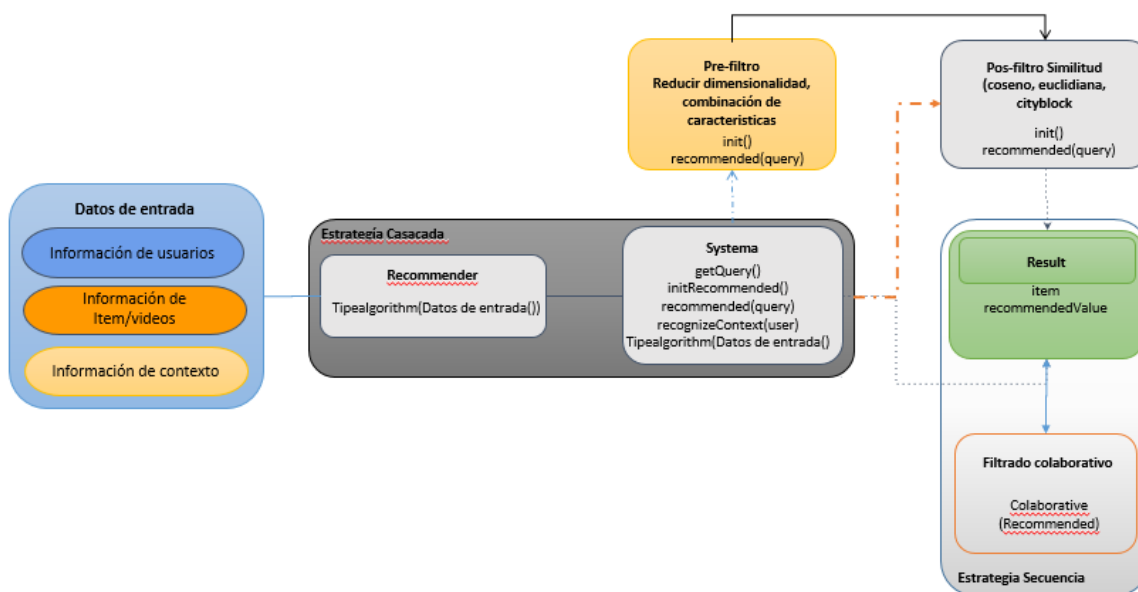


Figura 43. Proceso de recomendador híbrido CoCARE

La Figura 43, resume el proceso del recomendador híbrido. Primero se evalúa que datos se tienen del usuario y se escoge el recomendador que sirve para ese caso. Después se pasa la información al sistema y se le envía todos los datos al pre-filtro o pos filtro donde se mide la similitud de los datos según el recomendador señalado (el pre filtro solo se usa para combinar información contextual). Posteriormente pasa el resultado a un filtro colaborativo donde se evidencian las valoraciones de los ítems con mayor precisión a recomendar y también se filtran las que no han sido vistas por el usuario, con el fin de asignar en la lista los valores de valoración que han recibido los videos y que el usuario decida si quiere ver los que más han gustado a los otros usuarios.

3.1.3. Discusión Capítulo 3

Resultado 1. Al usar la metodología de diseño centrado en el usuario, se presume que el sistema será intuitivo y fácil de usar. Además las personas pueden usar cualquier dispositivo para usar el sistema y tendrá una vista agradable y de fácil navegación. Los colores son pertinentes y el tipo de letra legible lo que se facilita para personas de edad avanzada o con problemas de visión.

Resultado 2. Se implementó un sistema de recomendaciones consciente del contexto multiplataforma para actividad física, con recomendador híbrido que se espera facilite el uso de cualquier tipo de usuarios ya sea con poca información o con conocimiento previo de sus datos. Además, que permite hacer un seguimiento de la actividad

que realiza cada usuario y mantiene informado al experto en salud del progreso con el programa, además con múltiples funciones para estar motivando a los usuarios a adherirse al programa de promoción de actividad física.

3.1.4. Conclusión Capítulo 3

La arquitectura del sistema puede servir como referencia para otros sistemas contextuales orientados al dominio de salud.

El sistema de recomendaciones consciente del contexto CoCARE, se puede usar para el dominio de salud, cuenta con la flexibilidad de seguir incorporando datos al dataset y haciéndolo más robusto y con recomendaciones más precisas. Además cuenta con la facilidad de incorporar ítems por parte de expertos en el área de salud.

El uso de metodología de diseño centrado en el usuario, contribuye a un diseño usable y multiplataforma que se espera contribuya a la adherencia de los usuarios a los programas de actividad física y continuar con sus procesos en cualquier lugar y con un historial que le mantiene informado de su actividad y uso del sistema.

4. Análisis de resultados

4.1. Introducción capítulo 4

En este capítulo se describen las diferentes pruebas y evaluaciones realizadas con el fin de apoyar la toma de decisiones respecto al desarrollo del sistema de recomendaciones CoCARE. La evaluación incluye pruebas sobre que tipo de recomendador, las técnicas y otros aspectos específicos del dominio de salud.

Según la literatura (ver sesión 1.6) los resultados de la técnica de recomendación pueden variar mucho y darle ventajas a ciertas configuraciones sobre otras. Por ejemplo, la técnica de similitud utilizada, el tamaño de la vecindad, o incluso el algoritmo de predicciones, pueden presentar muy buenos resultados en un entorno y al mismo tiempo tener un mal rendimiento en otros escenarios. Por esta razón, algunos investigadores coinciden en que debe hacerse una evaluación en la que se consideren estas características con un test offline donde las pruebas se hacen únicamente con los datos contenidos en el dataset, y posteriormente una evaluación online donde se utilizan usuarios reales.

Para esta tesis, se inició con la prueba offline y se determinó en el dominio de salud específicamente actividad física que tipo de recomendador (clásico o un contextual) entrega mejores resultados. Para ello se realizaron pruebas con diferentes tipos de recomendadores y diferentes medidas de similitud (coseno, distancia euclidiana y cytyblock), evaluando a través de métricas de evaluación (Precisión, recall y F1score) cuales recomendadores y medidas de similitud generan mejores resultados. También se identificó que el enfoque híbrido presentó mejores resultados para los datos de CoCARE.

Después de la prueba offline, se procede a implementar el recomendador seleccionado en el sistema CoCARE. Una vez se tiene un piloto, se realiza una prueba online con usuarios reales donde se evalúa la experiencia y satisfacción del usuario con un cuasi-experimento transversal prospectivo que se realizó para medir la experiencia y satisfacción del usuario con base en el test de SUS [148] y algunas métricas de usabilidad de la ISO/IEC 25000 [149], [150].

En este capítulo, se entregan los resultados y el análisis de las diferentes pruebas que se realizaron para la selección del tipo de recomendador a usar en el sistema CoCARE (ver sesión 3.1.3) y los resultados del cuasi-experimento. Dando respuesta a las siguientes preguntas:

1. ¿Qué tipo de recomendadores clásicos o contextuales son más precisos y eficientes para este tipo de sistemas conscientes del contexto en el dominio de salud?
2. ¿Qué tipo de recomendadores deben usarse para disminuir los problemas de los recomendadores clásicos como arranque en frío, dispersión y/o sobreespecialización de la recomendación?
3. ¿Qué grado de satisfacción y usabilidad tiene el sistema CoCARE?

4.2. Definición de recomendadores y medidas de similitud a evaluar

En la Figura 44 se muestra la dinámica de las pruebas offline que se realizaron en esta tesis. En primer lugar, se dividen en pruebas de recomendadores clásicos sin considerar características de contexto (llamaremos cada sistema SisRec) y contextuales (llamaremos cada sistema CARS). En segundo lugar se probaron 3 enfoques: 1) basado en conocimiento, 2) basado en contenidos, 3) reducción de dimensión; cada uno de estos tipos fueron implementados con tres funciones de similitud diferentes (de coseno, distancia euclidiana y cityblock) y se usaron tres métricas de evaluación (precisión, recall y F1 Score). En el Anexo A y C, se puede ver el desarrollo de los algoritmos probados para esta tesis.

El dataset fue adaptado con datos de usuario del proyecto Simetic financiado por Colciencias implementado en la Universidad del Cauca [151], con datos contextuales del proyecto [102] modelo de un sistema consciente del contexto implementado en la Universidad del Cauca (865 instancias) y datos de ítems (videos) del proyecto neurotraining financiado por la Vicerrectoría de investigaciones de la Universidad del Cauca (210 videos).

Para estas pruebas se usó Python y se utilizó la implementación de scikit-learn, que es más rápida y admite matrices dispersas. Para la prueba, se realizarán varias ejecuciones de los algoritmos propuestos, variando los correspondientes parámetros de entrada.

Inicialmente se hace una prueba de vecindad, para ver cuantos videos son mejor recomendar en el caso de sistemas clásicos. En ambos casos (RS clásicos y contextuales) lo mejor se da con 5 videos (ver Tabla 7 y Tabla 8). Como los contextuales se basan en el pre-filtro basado en recomendadores clásicos, entonces se define también $K=5$ para todas las pruebas.

Tabla 7. Kn a recomendar basado en contenido

	Top 5	Top 10	Top 15
Precisión	0,5212	0,4789	0,3290
Recall	0,0931	0,0910	0,0789

Tabla 8. Kn a recomendar basado en conocimiento

	Top 5	Top 10	Top 15
Precisión	0,6811	0,5121	0,3623
Recall	0,0986	0,0971	0,0881

Lo que se busca con estas pruebas es realizar recomendaciones de K=5 vídeos y determinar lo siguiente:

- Estimación de los mejores parámetros o información de entrada (usuarios, ítems y/o contexto) para los recomendadores propuestos.
- Comparación entre los recomendadores, definir qué tipo de función de similitud se comporta mejor con los datos de entrada.
- Comparación de las medias obtenidas para cada recomendadores clásicos o contextuales y definir cuál se implementará en el sistema CoCARE.

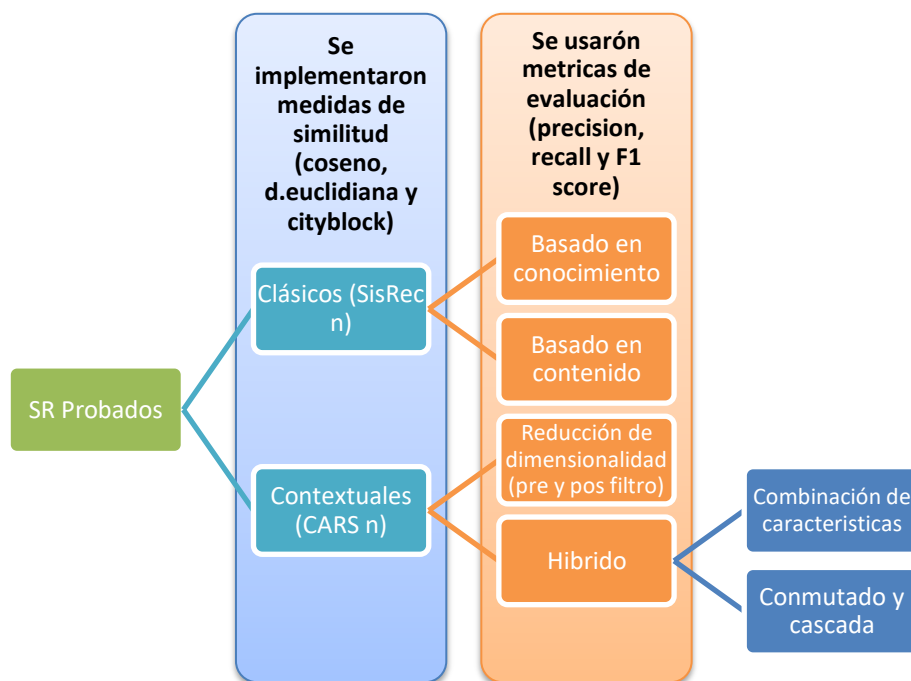


Figura 44. Esquema de pruebas offline de recomendadores

(Fuente: elaboración propia)

En la Figura 45 se muestra el proceso de prueba que se siguió para el caso de los sistemas de recomendaciones clásicos (SisRec1 y SisRec2). La Figura 46 muestra el proceso de pruebas que se siguió en el caso de los sistemas de recomendaciones contextuales (CARS1).

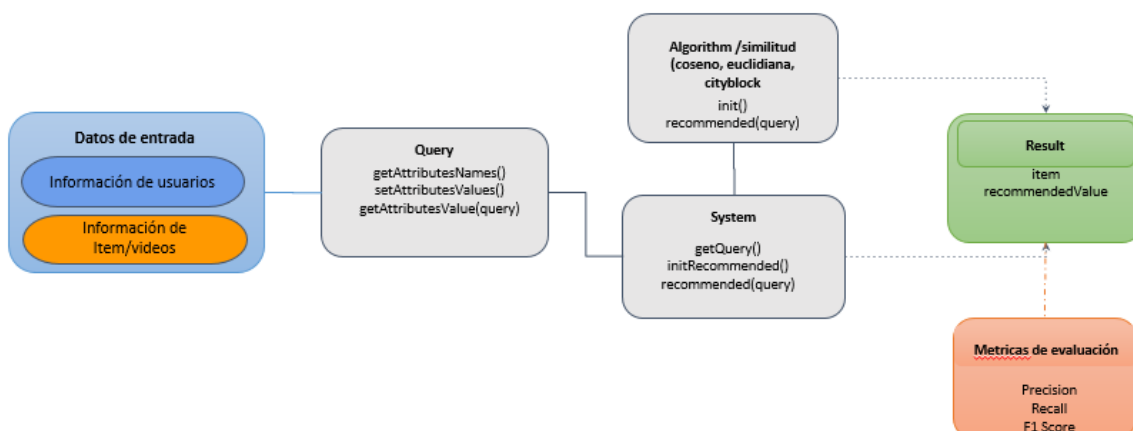


Figura 45. Proceso de prueba de los sistemas de recomendaciones clásicos.

(Fuente: elaboración propia)

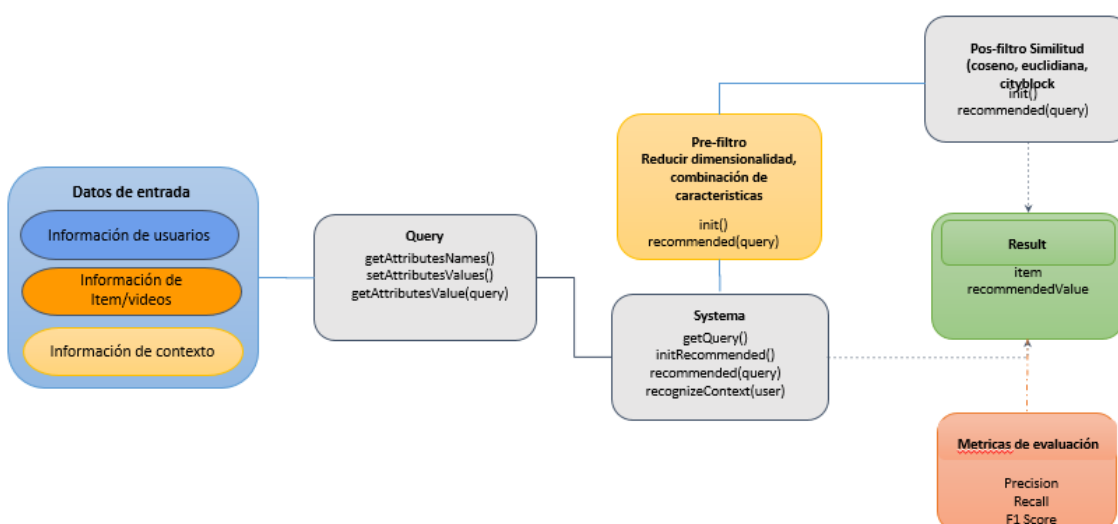


Figura 46. Proceso de prueba de los sistemas de recomendaciones contextuales

(Fuente: elaboración propia)

4.2.1. SisRec 1. Basado en conocimiento sin contexto

Este sistema recomienda ítems (videos de actividad física) basados en inferencias sobre las preferencias y necesidades del usuario. Cuenta con un conocimiento previo del perfil del usuario basado en el modelo ontológico OntoCocare propuesto en esta tesis. Este recomendador busca identificar cómo un ítem en particular, puede

satisfacer la necesidad de un usuario y que tan precisa es la posible recomendación.

Para realizar este recomendador basado en conocimiento se usó la técnica de razonamiento basado en casos[105], la cual se basan en la utilización de métricas para recomendar productos similares a los ya valorados por el usuario (ver descripción en la sesión 3.1.6).

Las Tabla 9 y Tabla 10 muestran los metadatos del dataset que se usó para el conocimiento de los recomendadores que se probaron.

Tabla 9. Datos de data set para el recomendador de conocimiento

Datos Usuario	Detalle
ide	Es el identificador de usuario
nombre	nombre completo sub dividido como en la ontología por nombre y apellido
imc	Se pide Talla y peso y el sistema lo calcula y posteriormente se evalúa en que rango está? Normo_peso, sobrepeso, bajo_peso.
Traumatismo	Motriz, sin traumatismo
enfermedades	diabetes, hipertensión, sin riesgo
Tipo de Intervención	cardio, ejercicio, pausas activas, ninguna
categoria	este dato lo pone el experto de salud cuando lo evalúa. 106ipertensi: condición 106ipert mala (CFM), 106ipertens 106ipert regular (CFR), condición 106ipert buena (CFB), condición 106ipert excelente (CFE)
compania	si o no
localizacion	casa, trabajo, lugar fuera
etnia	Afro, 106iperten, campesino, room, otro
ciclo_de_vida	joven o adulto se determina por rango de edades (< 30 o >30)
tiempo	Mañana, tarde o noche. Tiempo en que dese ase le recuerde su recomendación
hora	Hora en que el sistema notificará al usuario y recordará.
horadesayunoA horadesayunoB	Con estos datos el sistema obtiene un horario diario de las actividades del usuario.

horaalmuerzoA	
horaalmuerzoB	
horacenaA	
horacenaB	
video_visto	cuales videos ha visto
puntuación	valoración que les dio a los videos
duración_video	tiempo que alcanzo a ver el video
Actividad_fisica	valores 0 – 5 (0 no hay actividad, 1 más intensidad de la actividad hasta 5 actividades más o 107ipertensi)
ubicación GPS	latitud y longitud (confirmar que este en casa, o en otro sitio conocido)

Tabla 10. Datos de dataset de items

Datos Item (video)	Detalle
Categoría	CFM, CFR, CFB.CFE
Descripción	Descripción del video. El sistema toma automáticamente los datos desde Youtube, la cual el experto en salud la puede usar o modificar. El otro caso son videos que sube el experto desde su almacenamiento interno del dispositivo, el puede agregar la descripción que desee.
Keywords	5 palabras que referencian al video
Imc	bajo_peso, normo_peso, sobrepeso, obesidad
Ciclo De Vida	adolescentes_adultos, adultos
Etnia	Mestizo, room, afrocolombiano, otro
Traumatismo	motriz, visual, auditivo, sin_traumatismo
Uso_Sx	salud, belleza, deporte
Enfermedad Cardiovascular	diabetes, hipertensión, sin_riesgo
Duración_video	Tiempo que dura.
Puntuación	Valoraciones del video

4.2.1. SisRec 2. Basado en contenidos sin contexto

Esta prueba se basa principalmente en la descripción de los ítems (videos) de la plataforma y la información de perfil de los usuarios para generar las recomendaciones. Un ítem es representado por su descripción y por palabras importantes relacionadas con ese ítem. A partir de ello, se buscan coincidencias entre esa representación y el perfil del usuario. Es por esto por lo que este tipo de sistemas son muy eficaces en el caso de la recomendación de ítems nuevos, ya que se basan en las características del ítem y no en las inexistentes valoraciones del mismo.

Así como lo muestra la Figura 45, primero se hace la extracción de la información básica para hacer una representación en palabras clave de toda la información que describe a los ítems. Luego el sistema toma estos datos y con el aprendizaje basado en el perfil de usuario, trata de generar un modelo específico para cada usuario para predecir sus intereses en los diferentes ítems teniendo en cuenta su actividad y las valoraciones realizadas. Este modelo de aprendizaje personalizado para cada usuario objetivo se construye a partir de un conjunto de datos de entrenamiento de forma muy similar a como se usa en modelos de clasificación. Por último se aplica cada una de las funciones de similitud y se evalúan midiendo el número de recomendaciones que le gustarán al usuario (Ver Figura 47, Figura 50 y Figura 53).

4.2.2. CARS 1. Consciente del contexto

Como ya se ha mencionado en la sesión 3.1.8, para sistemas contextuales se hace una reducción de dimensión, para ello usaremos el pre y pos filtrado que tienen lugar antes y después de hacer la predicción utilizando un RS clásico.

Como se evidencia en la Figura 46 después de extraer los datos de entrada, se pasa a reducir la dimensión, para ello se hace un primer filtro de combinación de características de manera que una característica de contexto va a ser integrada como una nueva característica para el resto de estrategias de recomendación, así con cada una de ellas. Esta etapa es muy importante para maximizar la efectividad de los sistemas basados en contexto. En este punto la ontología OntoCoCARE ofrece conceptos que sirven como elementos clave en los recomendadores sensibles al contexto ya que se incluye conocimiento adicional sobre el dominio que puede ser comprendido y utilizado en la siguiente fase del pos filtro, donde se realiza la similitud del conocimiento siguiendo el mismo proceso del sistema de la sesión 4.2.1.

En este pos filtrado, se toman en cuenta la realimentación (feedback) directa e indirecta, considerando los datos del contexto que están variando continuamente

y los indirectos que son los datos de la retroalimentación del sistema de acuerdo a la navegación y actividad de los usuarios. Los resultados de esta prueba se pueden ver en (Figura 49, Figura 52 y Figura 55)

4.2.3. CARS 2. Híbrido contextual

En la sesión 3.1.3 se describieron las diferentes técnicas de recomendación, cada una tiene sus ventajas y produce buenos resultados, sin embargo también tienen sus desventajas como el arranque en frío o la adquisición de conocimiento.

Para esta tesis, se busca aprovechar las ventajas de cada uno de los recomendadores que se han probado en las sesiones anteriores SisRec y CARS, por eso se optó por hacer un sistema de recomendaciones consciente del contexto con enfoque híbrido siguiendo las estrategias de recomendación híbrida que combinan sistemas de recomendación desarrollados anteriormente (ver sesión 3.1.7).

Este recomendador híbrido para CoCARE cuenta con la combinación de 4 tipos: 1) filtrado colaborativo basado en las valoraciones de los ítems más populares, que soluciona el problema de hacer recomendaciones a usuarios nuevos e invitados que no tienen datos de usuarios. Se combina con el 2) basado en contenido, haciendo más precisas las recomendaciones cuando el usuario aporta más información de sus intereses mediante filtros de búsqueda. Otro recomendador a combinar es el 3) basado en conocimiento para cuando los usuarios no facilitan información contextual y el más importante es el 4) CARS 1 consciente del contexto cuando se tienen los datos suficientes para ser usado.

Al combinar los enfoques de filtrado colaborativo y basado en contenido se abordan problemas como la dispersión y la falta de información sobre las características de usuario. Además, con los recomendadores basados en conocimiento e información contextual, hacemos más precisa la recomendación y podemos eliminar la sobre-especialización del recomendador basado en conocimiento sin contexto.

Según Burker [147] existen siete métodos diferentes para combinar estrategias de recomendación. En esta tesis se usan 2 métodos (ver Figura 42) de acuerdo a la necesidad (ver la sesión 3.1.7). En primer lugar, una estrategia de conmutación, en este caso, en lugar de ejecutar todas las estrategias simultáneamente, el sistema tiene criterio para conmutar entre ellas. El uso de cada recomendador depende de la cantidad de información de ítem, usuario y contexto tenga el sistema.

Cuando el sistema no cuenta con información de usuario (esta como rol; Invitado) se usa filtrado colaborativo para hacer la recomendación. A medida que el usuario comienza a dar más información, por ejemplo, filtrar por búsqueda (usa buscador) o registrar datos adicionales a los formularios que el Sistema ira preguntando en el tiempo (encuestas), CoCARE puede cambiar a basado en contenido o en el mejor de los casos si llena la información mínima para usar el de basado en conocimiento y consciente del contexto.

La segunda estrategia es en cascada, que funciona de manera secuencial (pre-filtro y pos filtro). Primero se ejecuta una de las estrategias de recomendación y obtiene un primer conjunto de ítems a ser incluidos en la recomendación final dada por el recomendador consciente del contexto.

4.3. Pruebas offline RS clásicos Vs Contextuales

4.3.1. Plan de pruebas offline RS clásicos Vs Contextuales

Las pruebas que se realizaron se basan en 3 enfoques (ver Figura 44):

1. Tipos de recomendadores clásicos o contextuales: se definieron 3 tipos, 2 clásicos y 1 contextual. Esto con él fin de identificar si la información del contexto influía positivamente en la precisión de la recomendación.
2. Medidas de similitud: se probaron 3: cityblock, cosenos y distancia euclidiana. Los recomendaores clásicos y contextual se probaron con estas tres medidas. Así se evaluó que medida de similitud debía implementarse en cada caso y obtener mayor precisión en la recomendación.
3. Métricas de evaluación: se implementaron 3: precisión, recall y F1 score, para cada una de las medidas de similitud de cada recoemendaor.

La prueba offline se hace a partir de un método de sustitución leave-one-out. Se sustituye algunos valores o elementos de la solución antigua por otros adecuados al problema nuevo, para determinar predicciones generadas a partir el dataset de entrenamiento. Posteriormente se aplican las métricas de evaluación (ver sesión 3.1.2).

Las pruebas de los algoritmos para medir la similitud se desarrollaron sobre Python y la implementación de scikit-learn, que es más rápida y admite matrices dispersas. Para las pruebas, se realizarán varias ejecuciones de los algoritmos propuestos, variando los correspondientes parámetros de entrada según el enfoque que se estaba probando (ítem, usuario y/o contexto).

En esta sección se comparan los resultados obtenidos de las diferentes pruebas de los enfoques anteriores (ver Tabla 11, Tabla 12 y Tabla 13). La comparación de los algoritmos utilizados se basa en la precisión de recomendar $K=5$ ítems, es decir recomendando 0 (ninguno ítem), 1, 2, 3, 4 y 5 vídeos adecuados para el usuario (que se ajusten a su perfil). La lista debe ser por prioridad, es decir que el más adecuado ira de primero y el menos porcentaje de precisión ira de quinto.

Tabla 11. Comparativa de Precisión

		Precisión					
		0%	20%	40%	60%	80%	100%
Basado en contenido	Cityblock	107	25	19	17	19	23
	Coseno	105	19	17	17	29	23
	Euclidean	103	21	15	19	27	25
Basado en conocimiento	Cityblock	111	19	21	19	21	19
	Coseno	107	13	23	21	23	23
	Euclidean	107	11	25	21	23	23
R-Contexto	Cityblock	61	23	27	32	34	34
	Coseno	74	21	25	29	29	32
	Euclidean	65	21	25	27	34	38

De la Tabla 11 se observa, la fila de porcentajes 0%,20%,40%,60%,80% y 100% que hace referencia al número de videos que estará recomendando bien el algoritmo, según la posición de la recomendación en la lista de los $k=5$. Por ejemplo, el 100% es el primer video de la lista que vera el usuario, la tabla se lee: para un recomendador basado en contenido con similitud de cityblock se obtienen 23 ítems buenos en la primer posición de la lista de los 5 videos a recomendar, con similitud de coseno 23 videos y con euclidiana 25 videos. Si comparamos este primer resultado diríamos que el mejor resultado es con distancia euclidiana. Así mismo se hace la comparación para las otras Tabla 12 y Tabla 13 considerando las métricas **Recall y F1 score**, aunque se comporta de forma similar que precisión, en esta ocasión ha sido útil mostrar

cuántos no son recomendados bien, cuántos están por debajo del 50% y cuántos por encima de este valor.

Tabla 12. Comparativa de Recall

		Recall		
		0	< 50%	> 50%
Basado en contenido	Similitud			
	Cityblock	111	40	59
	Coseno	109	44	57
Basado en conocimiento	Euclidean	113	40	57
	Cityblock	111	40	59
	Coseno	113	44	53
R-Contexto	Euclidean	111	44	55
	Cityblock	57	67	86
	Coseno	74	53	84
	Euclidean	69	50	90

Tabla 13. Comparativa de F1 Score

		F1 Score		
		0	< 50%	> 50%
Basado en contenido	Similitud			
	Cityblock	107	36	67
	Coseno	118	32	61
Basado en conocimiento	Euclidean	107	32	71
	Cityblock	116	44	50
	Coseno	118	40	53
R-Contexto	Euclidean	105	42	63
	Cityblock	48	74	88
	Coseno	48	76	86
	Euclidean	71	59	80

4.3.2. Resultados de pruebas offline RS clásicos Vs Contextuales

4.3.2.1. Resultados Métrica Precisión

Precisión (ver Ecuación 4) es la primera métrica que se compara entre los distintos algoritmos para los recomendadores probados: basado en contenido, en conocimiento y con información contextual.

Para este apartado las gráficas comparativas (ver Figura 47, Figura 48 y Figura 49), se describen así: el eje X representa los K=5, es decir el 100% es el ítem que se recomienda de primero en la lista de los K=5, el 80% será el segundo en la lista y así sucesivamente. El eje Y representa el número de videos con precisión que se recomiendan y los colores representan el algoritmo a usar para la similitud.




Figura 47. Comparativa de Precisión recomendador basado en contenido.

(Fuente: elaboración propia)




Figura 48. Comparativa de Precisión recomendador basado en conocimiento.

(Fuente: elaboración propia)




Figura 49. Comparativa de Precisión recomendador basado en contexto.

(Fuente: elaboración propia)

En los resultados que se muestran en las anteriores figuras (Figura 47, Figura 48 y Figura 49) con relación a la precisión se evidencia:

1. En primer lugar, con relación al tipo de recomendador (clásico o contextual) con mayor precisión es el RS consciente del contexto. Así mismo se puede observar una mejora en algunos algoritmos al incluir el contexto dentro de la similitud de usuarios. También es importante notar que el algoritmo cuando se

le incluye contexto mejora en la precisión cerca de 40% comparada con los clásicos.

2. Segundo, el algoritmo que mayor precisión genera en los porcentajes > 60% es la distancia euclidiana.
3. Finalmente, comparando los recomendadores basados en contenido y conocimiento, las diferencias en la precisión son mínimas, pero esto no quiere decir que son malos recomendadores, solo que para los datos con los que se cuentan el incluir contexto mejora notablemente la precisión de la recomendación.

4.3.2.1. Resultados Métrica Recall

Recall (ver Ecuación 5) esta métrica busca comparar cuantos ítems están bien recomendados y cuantos hacen parte de una mala predicción. Las gráficas comparativas (ver Figura 50, Figura 51 y Figura 52), se describen así: el eje X representa que han sido recomendados bien con un porcentaje superior a 50%, y los que no fueron recomendados adecuadamente. El eje Y representa el número de videos con eficiencia que se recomiendan y los colores representan el algoritmo a usar para la similitud.




Figura 50. Comparativa de Recall recomendador basado en contenido.

(Fuente: elaboración propia)




Figura 51. Comparativa de Recall recomendador basado en conocimiento.
(Fuente: elaboración propia)




Figura 52. Comparativa de Recall recomendador basado en contexto.
(Fuente: elaboración propia)

En los resultados que se muestran en las anteriores figuras de la métrica Recall se concluye que:

1. En primer lugar, con relación al tipo de recomendador (clásico o contextual) con mayor valor es el RS consciente del contexto. Se puede ver como incluir información contextual mejora la precisión de la recomendación en cerca de 100% comparada con los clásicos.
2. Segundo, el algoritmo con mejor resultado para los clásicos fue cityblock y para RS contextuales fue la distancia euclidiana, aunque la diferencia no fue muy amplia entre algoritmos.

4.3.2.1. Resultados Métrica F1 score

F1 score (ver Ecuación 6) da respuesta a la pregunta: ¿Qué proporción de elementos que le gustan a un usuario en realidad fueron recomendados?, en las gráficas comparativas (ver Figura 53, Figura 54 y Figura 55), se evidencia como los sistemas se comportan frente a la satisfacción del usuario. Las gráficas se interpretan así: el eje X representa cuantas recomendaciones que le gustan al usuario le fueron recomendadas bien con porcentaje superior a 50%, y los que no fueron recomendados adecuadamente. El eje Y representa el número de videos que fueron bien sugeridos y los colores representan el algoritmo a usar para la similitud.




Figura 53. Comparativa de F1 Score recomendador basado en contenido..

(Fuente: elaboración propia)




Figura 54. Comparativa de F1 Score recomendador basado en conocimiento.

(Fuente: elaboración propia)




Figura 55. Comparativa de F1 Score recomendador basado en contexto.

(Fuente: elaboración propia)

En los resultados que se muestran en las anteriores figuras de la métrica F1 score se evidencia que:

1. En primer lugar, con relación al tipo de recomendador (clásico o contextual) con mayor valor es el RS consciente del contexto. Se puede ver como incluir

información contextual mejora la precisión de la recomendación en cerca de 100% comparada con los clásicos.

2. Segundo, el algoritmo con mejor resultado para los clásicos fue la distancia euclidiana y para el contexto fue cityblock, aunque la diferencia no fue muy significativa entre algoritmos.

4.4. Pruebas Online experiencia de usuario y satisfacción

Para la evaluación del sistema se realizó un cuasi-experimento, transversal, prospectivo; donde se siguieron los estándares ISO / IEC 25000 que se basa en ISO 9126 [150] y SUS [148]. Se evaluaron algunas características de usabilidad proporcionadas por los estándares (ver Tabla 14).

Los instrumentos utilizados para esta evaluación fueron: a) entrevista personal estructurada, b) cuestionarios y c) estructuración de observación directa. Basado en la recomendación de ISO 25000, seleccionamos siete (7) medidas para evaluar la usabilidad (Ver **¡Error! No se encuentra el origen de la referencia.** B) y el test de SUS para medir la escala de satisfacción del usuario que son 10 ítems a evaluar. Cada medida tenía un rango [0..1] donde los valores más cercanos a 1 son mejores. Además de la usabilidad, también se han evaluado el atractivo y la satisfacción que se mide con la escala SUS.

El estudio de evaluación incluyó a 12 participantes, 3 hombres y 3 mujeres, entre 19 y 35 años; 2 mujeres, entre 32 y 40 años; finalmente 2 hombres y 2 mujeres, entre 42 y 60 años. Las relaciones sobre su IMC (índice de masa corporal) fueron: 1 mujer de 20 años tiene bajo peso, 4 hombres y 5 mujeres, entre 19 y 60 años tienen rango normal, y 1 hombre y 1 mujer entre 42 y 60 años tienen sobrepeso. En el Anexo B se detalla el cuasi-experimento.

4.4.1. Resultados Pruebas Online

La Tabla 14 resume las medidas a evaluar dentro del cuasi-experimento, en el Anexo B se describe en detalle cada una de estas medidas y sus subcaracterísticas y atributos. También las tablas de los resultados de donde se obtuvieron estos valores.

Tabla 14. Características evaluadas

Medida	Característica
Comprensión:	Características del producto de software que permiten al usuario comprender si el software es apropiado y cómo se puede usar para realizar algunas tareas en condiciones particulares de uso. Funciones evidentes, funciones que son evidentes para el usuario. La puntuación de la medida fue de aproximadamente 0,99. Fácil de entender, significa que la interfaz de usuario fue entendida por los usuarios. El puntaje de la medida fue 0,96. Esto significa aproximadamente 100% de certeza, es decir, que las operaciones del sistema son evidentes.
Operatividad:	Características del producto de software que permite al usuario operarlo y controlarlo. Operación fácil de cancelar para un usuario: funciones que el usuario puede cancelar antes de que se complete la operación. El puntaje fue de 0,8. Operación fácil de deshacer de un usuario: funciones que el usuario puede deshacer. El puntaje fue de 0,9. Capacidad para monitorear el estado de una operación: describe la capacidad de monitorear el estado de las operaciones. La puntuación en esta medida fue de 0,97.
Aprendizaje:	Características del producto de software que permite al usuario conocer la aplicación. Claridad de los mensajes: el objetivo de esta característica era identificar qué proporción de mensajes es clara y se explica por sí misma. La puntuación obtenida fue de 0,85. Claridad de los elementos de la interfaz: describe que los elementos de la interfaz son claros y se explican por sí mismos. La puntuación obtenida fue de 0,92.
Atractivo:	Características del producto de software para ser atractivo para el usuario. Interacción atractiva El puntaje fue de 0,95. Aquí es posible observar el

	<p>porcentaje de sentimientos que experimentaron los usuarios frente a la aplicación, concluyendo que el 60% de los usuarios sintieron tranquilidad, algunos de ellos expresaron que se debió a las recomendaciones que brindaba la aplicación. El 40% de los usuarios sintió alegría, 30% de los participantes sintió emoción y un 10% de ellos sintió aburrimiento, Los sentimientos de tristeza y enojo no tuvieron ningún porcentaje. Es importante resaltar que la mayoría de los usuarios tuvieron sentimientos positivos frente a la aplicación y en general en todo su contenido.</p>
<p>Escala de satisfacción-SUS:</p>	<p>A nivel mundial, mide la usabilidad desde un fuerte acuerdo hasta un fuerte desacuerdo. Satisfacción: La medición se realizó con él SUS (Escala de usabilidad del sistema). La puntuación obtenida fue de 94,25 puntos en un rango de 0-100, lo que indica el buen nivel de usabilidad del sistema de recomendación COCARE.</p>

La evaluación del estudio de caso CoCARE mostró buenos resultados: a) El sistema de recomendaciones aseguró el cálculo e inferencia de los datos del usuario y la provisión de recomendaciones de contenido multimedia para actividad física y dieta saludable con una precisión del sistema superior al 90%. Con respecto a la usabilidad, se obtuvo una retroalimentación positiva de más del 90% para la mayoría de las medidas de usabilidad.

4.4.2. Discusión Capítulo 4

Resultado 1. Se comprueba que para el sistema recomendador consciente del contexto para promoción de actividad física CoCARE, debe usarse un recomendador híbrido. Este recomendador híbrido se compone de recomendador basado en filtrado colaborativo, basado en conocimiento y contextual basado en pre y pos filtro.

Resultado 2. Luego estas mismas pruebas mostraron que el incluir el contexto dentro del cálculo de similitud mejora la precisión y la eficiencia de la recomendación

casi en un 100 %. Esto demuestra que un recomendador consciente del contexto en el dominio de la salud y en actividad física tiene mayor precisión y eficiencia en las recomendaciones dadas al usuario.

Resultado 3. Las pruebas de los recomendadores garantizan una precisión buena para un $K=5$ de ítems a recomendar, así los usuarios recibirán recomendaciones adecuadas y que satisfagan sus necesidades; esto cuando se usa el algoritmo de distancia euclidiana, ya que se comprobó que fue uno de los que arrojó mejor promedio de buenas recomendaciones.

Resultado 4. El grado de usabilidad y satisfacción del usuario frente al Sistema CoCARE fue superior al 90% demostrando que es un sistema pertinente para ser usado en programas de promoción de actividad física, fácil de usar sin importar la edad o la experiencia con TIC, además que las recomendaciones impartidas son satisfactorias y atractivas con un diseño adecuado, generando un porcentaje superior al 80% de emociones positivas, esto disminuye el grado de frustración incrementando la motivación y animo de querer usar el sistema y así aumentar la adherencia a los programas de salud.

Resultado 5. Por otro lado, la IU de CoCARE es fácil de entender, aproximadamente 100% de certeza, es decir, que las operaciones del sistema son evidentes, fácil de cancelar para un usuario antes de que se complete la operación. Claridad de los elementos de la interfaz: describe que los elementos de la interfaz son claros y se explican por sí mismos.

Resultado 6. Se deja a disposición de futuras investigaciones un data set con datos de usuario, ítems y contexto para el dominio de la salud. Cabe aclarar que por ahora está restringido para la Universidad del Cauca debido a que los datos hacen parte de diferentes proyectos de investigación que requieren proteger la privacidad de los datos.

4.5. Conclusiones Capítulo 4

1. Con las múltiples pruebas realizadas en este capítulo, Se concluye que los recomendadores no son inútiles ni imprecisos al obtener un rendimiento bajo en determinada prueba, solo depende del tipo de datos que podamos tener a la entrada para determinar cual es el mejor algoritmo de recomendación. Para esta tesis se cuenta con datos de usuario, ítem y contexto lo que permite al

recomendador entregar recomendaciones con mayor precisión y eficiencia. Al usar un recomendador híbrido como el propuesto en esta tesis, se disminuyen algunos problemas de otros recomendadores clásicos como es el arranque en frío y/o la sobrespecialización de la recomendación. Por esta razón en recomendadores de salud se recomienda usar información contextual y combinar diferentes recomendadores.

Con relación a la experiencia de usuario, se llega a la conclusión que el usar metodología DCU, ayuda a mejorar la apariencia del sistema, la navegabilidad, tener rutas más cortas, iconos entendibles, facilidad de uso y entrega de recomendaciones satisfactoria. Ayudando a incrementar la permanencia de los usuarios en la plataforma y que la usen con mayor frecuencia.

5. Conclusiones y Trabajos futuros

5.1. Conclusiones

En este capítulo se describen las principales conclusiones de esta tesis de doctorado.

1. El estado del arte referenciado en esta tesis, contribuye a futuras investigaciones, es actualizado y los investigadores podrán encontrar nichos de investigación que requieren ser abordados en los sistemas de recomendaciones y sus distintas técnicas.
2. La ontología OntoCoCARE representa semántica del conocimiento sobre los datos que se integran al dominio de salud, obteniendo un conjunto de clases que se consideran fundamentales en los sistemas de recomendaciones clásicos y contextuales considerando información de usuario, ítem y contexto.
3. Se logró una adaptación de la ontología para sistemas de recomendaciones a la ontología de alto nivel BFO, incluyendo información contextual. Obteniendo una ontología flexible producto de contar con la base de ontologías de más alto nivel al de la aplicación, y ser adaptada para otra especialidad en el dominio de salud y a evolucionar iterativamente con el tiempo.
4. El modelo ontológico propuesto ofrece una interpretación compartida de los datos/información utilizados en las técnicas de recomendación para garantizar la consistencia y precisión de las recomendaciones entregadas al usuario.
5. El uso de otras ontologías como base para el desarrollo de esta ontología facilita su interoperabilidad semántica con ontologías de otros ámbitos y permite considerar varios fundamentos ontológicos para conceptualizar con fidelidad la realidad a representar. La confiabilidad en el proceso de recomendación de salud es de calidad y se da debido a que el manejo de los datos es estructurado y organizado dadas las características de OntoCocare.
6. La arquitectura del sistema CoCARE es genérica, flexible y fácil de adaptar a otros dominios que requieran información del contexto, sirve como referencia para otros sistemas contextuales.

7. Se propuso un recomendador híbrido, que recibe datos de usuario, ítem y contexto lo que permite al recomendador entregar recomendaciones con mayor precisión y eficiencia, además se disminuyen algunos problemas de otros recomendadores clásicos como es el arranque en frío y/o la sobreespecialización de la recomendación, se recomienda para futuros trabajos que usen información contextual.
8. Se concluye que los recomendadores no son inútiles ni imprecisos al obtener un rendimiento bajo en determinada prueba, solo depende del tipo de datos que podamos tener a la entrada para determinar cual es el mejor algoritmo de recomendación. La mejor opción es poder tener información de ítem, usuarios y contexto.
9. El uso de metodología de diseño centrado en el usuario, facilitó el proceso de creación del sistema CoCARE, logrando la maquetación web que asegura usabilidad dentro de la navegación y presentación de las interfaces de usuario propuestas, debido a que éste hace parte activa en el diseño para que finalmente la solución presentada se encuentre acorde a sus necesidades.
10. Los resultados obtenidos de la aplicación del cuasi-experimento definido permiten concluir que la interacción entre el usuario y el sistema es bueno porque cumple con las expectativas de los usuarios en un 90%, además de ser considerado como atractivo incentivando la adherencia a la aplicación para ser utilizada de manera regular para el apoyo de la promoción de la actividad física y la dieta saludable.
11. Para concluir que un sistema es satisfactorio al usuario es necesario obtener un puntaje mayor al 80% de satisfacción para estar entre el 10% de sistemas mejores evaluados donde en este punto es más probable que los usuarios recomienden el sistema a sus amigos. La tasa de satisfacción obtenida en la aplicación del experimento fue más del 90% confirmando así, que la aplicación brinda una buena experiencia de usuario.
12. CoCARE, permite a los expertos en salud hacer seguimiento continuo a sus pacientes y así poder mejorar la condición física de los mismos, obteniendo resultados positivos en su salud. Así se propicia una comunicación interactiva del paciente y el experto en salud, que actualmente la mayoría de sistemas para el dominio de salud no contemplan.

13. Esta tesis deja como referencia el código fuente y diferentes comparaciones de recomendadores para futuros trabajos de investigación. Este código es adaptable y los componentes son útiles para ser reutilizados en otros recomendadores que requieran considerar información contextual o que requieran un recomendador híbrido.

5.2. Trabajos futuros

Esta sesión contiene la lista de los trabajos futuros que se derivan de esta tesis.

1. Extender el rango de las características y datos más allá del dominio de actividad física, teniendo en cuenta otras dimensiones, como son el ámbito nutricional, el contexto en la dimensión multicultural y tradicional, otros dominios fuera del de salud, adaptación a los distintos sistemas de recomendaciones, etc.
2. Adaptar un módulo de seguimiento continuo en tiempo real mediante video streaming que capture datos de contexto adicionales que comprueben la condición física de la persona, los movimientos que los realice adecuadamente y reciba motivación en tiempo real con base en su actividad y movimiento.
3. Implementar un diseño experimental longitudinal y prospectivo, para valorar el progreso del estilo de vida de la persona y como se proyecta su estado de salud.

6. Referencias

- [1] World Health Organization, "Global status report on noncommunicable diseases 2010," *World Health*, 2010. [Online]. Available: http://whqlibdoc.who.int/publications/2011/9789240686458_eng.pdf.
- [2] U. González Pérez, "El concepto de calidad de vida y la evolución de los paradigmas de las ciencias de la salud," *Rev. Cuba. Salud Pública*, no. c, pp. 1–6, 2002.
- [3] S. Leka, A. Griffiths, and T. Cox, "La organización del trabajo y el estrés: Estrategias sistemáticas de solución de problemas para empedadores, personal directivo y representantes sindicales.," *Ser. protección la salud los Trab.*, 2004.
- [4] P. Krebs, J. O. Prochaska, and J. S. Rossi, "A meta-analysis of computer-tailored interventions for health behavior change," *Preventive Medicine*. 2010.
- [5] M. Solenhil, A. Grotta, E. Pasquali, L. Bakkman, R. Bellocco, and Y. T. Lagerros, "The effect of tailored web-based feedback and optional telephone coaching on health improvements: A randomized intervention among employees in the transport service industry," *J. Med. Internet Res.*, 2016.
- [6] K. Broekhuizen, W. Kroeze, M. N. M. Van Poppel, A. Oenema, and J. Brug, "A systematic review of randomized controlled trials on the effectiveness of computer-tailored physical activity and dietary behavior promotion programs: An update," *Annals of Behavioral Medicine*. 2012.
- [7] World Health Organization, "Recomendaciones Mundiales sobre Actividad Física para la Salud," *Geneva WHO Libr. Cat.*, 2010.
- [8] T. N. Robinson, "Community health behavior change through computer network health promotion: preliminary findings from Stanford Health-Net.," *Comput. Methods Programs Biomed.*, vol. 30, no. 2–3, pp. 137–44, 1989.
- [9] S. M. Slotmaker, M. J. M. Chin A Paw, A. J. Schuit, J. C. Seidell, and W. van Mechelen, "Promoting physical activity using an activity monitor and a tailored web-based advice: design of a randomized controlled trial [ISRCTN93896459].," *BMC Public Health*, vol. 5, p. 134, 2005.
- [10] B. Patel *et al.*, "Success of a comprehensive school-based asthma intervention on clinical markers and resource utilization for inner-city children with asthma in Chicago: The Mobile C.A.R.E. Foundation's asthma management program," *J. Asthma*, vol. 44, no. 2, pp. 113–118, 2007.
- [11] Y. J. Gschwind *et al.*, "ICT-based system to predict and prevent falls (iStoppFalls): Study protocol for an international multicenter randomized controlled trial," *BMC Geriatr.*, vol. 14, no. 1, 2014.
- [12] P. A. Abbott and A. Coenen, "Globalization and advances in information and communication technologies: The impact on nursing and health," *Nurs. Outlook*, vol. 56, no. 5, 2008.
- [13] G. Fergie, S. Hilton, and K. Hunt, "Young adults' experiences of seeking online information about diabetes and mental health in the age of social media," *Heal. Expect.*, vol. 19, no. 6, pp. 1324–1335, 2016.
- [14] "Una red es tan fuerte como su eslabón más débil | Dataprix TI."

- [Online]. Available: <https://www.dataprix.com/red-tan-fuerte-como-su-eslabon-mas-debil>. [Accessed: 02-Nov-2019].
- [15] M. Agudelo, “Desarrollar nuestro ecosistema digital para crecer con equidad y transformar el aparato productivo - ASIET,” <https://asiet.lat/actualidad/opinion/desarrollar-nuestro-ecosistema-digital-para-crecer-con-equidad-y-transformar-el-aparato-productivo/>, 2019. [Online]. Available: <https://asiet.lat/actualidad/opinion/desarrollar-nuestro-ecosistema-digital-para-crecer-con-equidad-y-transformar-el-aparato-productivo/>. [Accessed: 02-Nov-2019].
- [16] D. R. George, L. S. Rovniak, and J. L. Kraschnewski, “Dangers and opportunities for social media in medicine,” *Clin. Obstet. Gynecol.*, vol. 56, no. 3, pp. 453–462, 2013.
- [17] C. Ipsen, C. Ruggiero, B. Rigles, D. Campbell, and N. Arnold, “Evaluation of an online health promotion program for vocational rehabilitation consumers,” *Rehabil. Psychol.*, vol. 59, no. 2, pp. 125–135, 2014.
- [18] E. R. Weitzman, E. Cole, L. Kaci, and K. D. Mandl, “Social but safe? Quality and safety of diabetes-related online social networks,” *J. Am. Med. Informatics Assoc.*, vol. 18, no. 3, pp. 292–297, 2011.
- [19] L. Fernandez-Luque, R. Karlsen, and G. B. Melton, “HealthTrust: a social network approach for retrieving online health videos.,” *J. Med. Internet Res.*, vol. 14, no. 1, 2012.
- [20] EL Tiempo, “CES 2015: La internet personalizada es el corazón de muestra electrónica CES - Archivo Digital de Noticias de Colombia y el Mundo desde 1.990 - eltiempo.com,” 2015. [Online]. Available: <https://www.eltiempo.com/archivo/documento/CMS-15059512>. [Accessed: 02-Nov-2019].
- [21] A. Jain and V. Jain, “A Literature Survey on Recommendation System Based on Sentimental Analysis,” *Adv. Comput. Intell. An Int. J.*, vol. 3, no. 1, pp. 25–36, 2016.
- [22] F. Ricci, L. Rokach, and B. Shapira, “Recommender Systems: Introduction and Challenges,” in *Recommender Systems Handbook*, 2015, pp. 1–34.
- [23] A. Abbas, L. Zhang, and S. U. Khan, “A survey on context-aware recommender systems based on computational intelligence techniques,” *Computing*, vol. 97, no. 7, pp. 667–690, 2015.
- [24] L. Sharma and A. Gera, “A Survey of Recommendation System : Research Challenges,” *Int. J. Eng. Trends Technol.*, vol. 4, no. 5, pp. 1989–1992, 2013.
- [25] C. L. Sanchez-Bocanegra, F. Sanchez-Laguna, and J. L. Sevillano, “Introduction on health recommender systems,” in *Data Mining in Clinical Medicine*, 2014.
- [26] K. Petersen, R. Feldt, M. Mattsson, and S. Mujtaba, “Systematic Mapping Studies in Software Engineering EASE Theme E-Decision support for software testing View project Towards PhD View project Systematic Mapping Studies in Software Engineering,” 2008.
- [27] K. Petersen, S. Vakkalanka, and L. Kuzniarz, “Guidelines for conducting systematic mapping studies in software engineering: An update,” in *Information*

- and Software Technology*, 2015, vol. 64, pp. 1–18.
- [28] P. Brusilovsky and E. Millán, “User models for adaptive hypermedia and adaptive educational systems,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2007.
- [29] R. L. Goldstone and U. Wilensky, “Promoting transfer by grounding complex systems principles,” *Journal of the Learning Sciences*, vol. 17, no. 4. pp. 465–516, Oct-2008.
- [30] D. Toker, C. Conati, G. Carenini, and M. Haraty, “Towards adaptive information visualization: On the influence of user characteristics,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2012.
- [31] G. Westhorp, “Using complexity-consistent theory for evaluating complex systems,” *Evaluation*, 2012.
- [32] S. Weibelzahl and C. U. Lauer, “Framework for the Evaluation of Adaptive CBR-Systems.”
- [33] F. J. ARIAS S., J. A. JIMÉNEZ B., and D. A. OVALLE C., “Una aproximación metodológica para la construcción de sistemas tutoriales adaptativos multi-agente con énfasis en el modelo pedagógico,” *Av. en Sist. e Informática; Vol. 4, núm. 3 Av. en Sist. e Informática; Vol. 4, núm. 3 1909-0056 1657-7663*, 2009.
- [34] J. A. Recio-garcía, “jCOLIBRI CBR Framework Platform for developing CBR applications Motivation Platform = Reference Architecture + Implementation.”
- [35] C. Fröschl, “User Modeling and User Profiling in Adaptive E-learning Systems,” 2005.
- [36] C. C. Vo, T. Torabi, and S. W. Loke, “Towards context-aware task recommendation,” in *2009 Joint Conferences on Pervasive Computing, JCPC 2009*, 2009, pp. 289–292.
- [37] S. Sosnovsky and D. Dicheva, “Ontological technologies for user modelling,” *Int. J. Metadata, Semant. Ontol.*, 2010.
- [38] C. Bettini *et al.*, “A survey of context modelling and reasoning techniques,” *Pervasive Mob. Comput.*, 2010.
- [39] B. N. Miller, J. A. Konstan, and J. Riedl, “PocketLens: Toward a personal recommender system,” *ACM Trans. Inf. Syst.*, 2004.
- [40] S. De and K. Moessner, “A framework for mobile, context-aware applications,” in *16th International Conference on Telecommunications, ICT 2009*, 2009.
- [41] N. Bricon-Souf and C. R. Newman, “Context awareness in health care: a review.,” *Int. J. Med. Inform.*, vol. 76, no. 1, pp. 2–12, Jan. 2007.
- [42] G. Adomavicius and A. Tuzhilin, “Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 6. pp. 734–749, 2005.
- [43] M. Gaeta, F. Orciuoli, S. Paolozzi, and S. Salerno, “Ontology extraction for knowledge reuse: The e-learning perspective,” *IEEE Trans. Syst. Man, Cybern. Part A Systems Humans*, vol. 41, no. 4, pp. 798–809, 2011.
- [44] M. Schedl, P. Knees, B. McFee, D. Bogdanov, and M. Kaminskas,

- “Music Recommender Systems,” in *Recommender Systems Handbook*, Boston, MA: Springer US, 2015, pp. 453–492.
- [45] B. Smyth, “Case-based recommendation,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2007.
- [46] C. Mettouris and G. A. Papadopoulos, “CARS Context Modelling.”
- [47] P. Resnick, H. R. Varian, and G. Editors, “Recommender Systems,” *Commun. ACM*, vol. 40, no. 3, pp. 56–58, 1997.
- [48] Z. D. Champiri, S. R. Shahamiri, and S. S. B. Salim, “A systematic review of scholar context-aware recommender systems,” *Expert Systems with Applications*. 2015.
- [49] L. O. Colombo-Mendoza, R. Valencia-García, A. Rodríguez-González, G. Alor-Hernández, and J. J. Samper-Zapater, “RecomMetz: A context-aware knowledge-based mobile recommender system for movie showtimes,” *Expert Syst. Appl.*, 2015.
- [50] F. Ricci, B. Shapira, and L. Rokach, “Recommender systems: Introduction and challenges,” in *Recommender Systems Handbook, Second Edition*, 2015.
- [51] D. Jannach, M. Zanker, A. Felfernig, and G. Friedrich, *Recommender Systems: An Introduction - Dietmar Jannach, Markus Zanker, Alexander Felfernig, Gerhard Friedrich - Google Books*. 2010.
- [52] X. Liu and K. Aberer, “Towards a Dynamic top-N Recommendation Framework,” *Proc. 8th ACM Conf. Recomm. Syst.*, pp. 217–224, 2014.
- [53] P. Kouki, S. Fakhraei, J. Foulds, M. Eirinaki, and L. Getoor, “HyPER A Flexible and Extensible Probabilistic Framework for Hybrid Recommender Systems,” *Proc. 9th ACM Conf. Recomm. Syst. - RecSys '15*, pp. 99–106, 2015.
- [54] G. Lv, C. Hu, and S. Chen, “Research on recommender system based on ontology and genetic algorithm,” *Neurocomputing*, vol. 187, pp. 92–97, 2016.
- [55] W.-I. Park, J.-H. Park, Y.-K. Kim, and J.-H. Kang, “An efficient context-aware personalization technique in ubiquitous environments,” *Proc. 4th Int. Conf. Ubiquitous Inf. Manag. Commun. - ICUIMC '10*, p. 1, 2010.
- [56] C. Zheng, H. E. M. Song, and J. Song, “CMPTF: Contextual Modeling Probabilistic Tensor Factorization for recommender systems,” *Neurocomputing*, vol. 205, pp. 141–151, 2016.
- [57] C. Zhang *et al.*, “Multi-Imbalance: An open-source software for multi-class imbalance learning,” *Knowledge-Based Syst.*, vol. 174, pp. 137–143, Jun. 2019.
- [58] C. Martinez-Cruz, C. Porcel, J. Bernabé-Moreno, and E. Herrera-Viedma, “A model to represent users trust in recommender systems using ontologies and fuzzy linguistic modeling,” *Inf. Sci. (Ny)*, vol. 311, pp. 102–118, 2015.
- [59] S. Zhang, L. Yao, A. Sun, and Y. Tay, “Deep learning based recommender system: A survey and new perspectives,” *ACM Computing Surveys*. 2019.
- [60] Sangeeta and N. Duhan, “Collaborative filtering-based recommender system,” in *Advances in Intelligent Systems and Computing*, 2018.
- [61] N. M. Villegas, C. Sánchez, J. Díaz-Cely, and G. Tamura, “Characterizing context-aware recommender systems: A systematic literature review,” *Knowledge-Based Syst.*, 2018.

- [62] T. K. Paradarami, N. D. Bastian, and J. L. Wightman, "A hybrid recommender system using artificial neural networks," *Expert Syst. Appl.*, 2017.
- [63] K. Haruna *et al.*, "Context-aware recommender system: A review of recent developmental process and future research direction," *Applied Sciences (Switzerland)*. 2017.
- [64] G. Jawaheer, P. Weller, and P. Kostkova, "Modeling User Preferences in Recommender Systems: A Classification Framework for Explicit and Implicit User Feedback," *ACM Trans. Interact. Intell. Syst.*, vol. 4, no. 2, pp. 8:1–8:26, 2014.
- [65] K. F. Yeung and Y. Yang, "A proactive personalized mobile news recommendation system," in *Proceedings - 3rd International Conference on Developments in eSystems Engineering, DeSE 2010*, 2010, pp. 207–212.
- [66] S. McCallum, "Gamification and serious games for personalized health," in *Studies in Health Technology and Informatics*, 2012, vol. 177, pp. 85–96.
- [67] G. Dror, Y. Koren, Y. Maarek, and I. Szpektor, "I want to answer, Who has a question? Yahoo! answers recommender system," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2011, pp. 1109–1117.
- [68] B. Smith and G. Linden, "Two Decades of Recommender Systems at Amazon.com," *IEEE Internet Comput.*, 2017.
- [69] A. Tejada-Lorente, C. Porcel, J. Bernabé-Moreno, and E. Herrera-Viedma, "REFORE: A recommender system for researchers based on bibliometrics," *Appl. Soft Comput. J.*, vol. 30, pp. 778–791, 2015.
- [70] A. Krohn-Grimberghe, A. Nanopoulos, and L. Schmidt-Thieme, "A Novel Multidimensional Framework for Evaluating Recommender Systems."
- [71] A. Lommatzsch, "Real-time news recommendation using context-aware ensembles," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2014, vol. 8416 LNCS, pp. 51–62.
- [72] M. Aharon, E. Hillel, A. Kagian, R. Lempel, H. Makabee, and R. Nissim, "Watch-It-Next: A Contextual TV Recommendation System," 2015, pp. 180–195.
- [73] F. Ricci, L. Rokach, and B. Shapira, "Introduction to Recommender Systems Handbook," in *Recommender Systems Handbook*, 2011, pp. 1–35.
- [74] M. I. Martín-Vicente, A. Gil-Solla, M. Ramos-Cabrer, Y. Blanco-Fernández, and M. López-Nores, "Semantic inference of user's reputation and expertise to improve collaborative recommendations," *Expert Syst. Appl.*, vol. 39, no. 9, pp. 8248–8258, Jul. 2012.
- [75] C. Mettouris, A. P. Achilleos, and G. A. Papadopoulos, "A context modelling system and learning tool for context-aware recommender systems," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2013.
- [76] B. Towle and C. Quinn, "Knowledge Based Recommender Systems Using Explicit User Models," 2000.
- [77] C. C. Aggarwal and C. C. Aggarwal, "Knowledge-Based Recommender

- Systems,” in *Recommender Systems*, 2016.
- [78] M. Kunaver and T. Požrl, “Diversity in recommender systems – A survey,” *Knowledge-Based Syst.*, 2017.
- [79] J. A. Recio-García, P. A. González-Calero, and B. Díaz-Agudo, “Jcolibri2: A framework for building Case-based reasoning systems,” *Sci. Comput. Program.*, vol. 79, pp. 126–145, 2014.
- [80] J. R. Basto Diniz, C. A. G. Ferraz, and H. Melo, “An architecture of services for session management and contents adaptation in ubiquitous medical environments,” *Proc. 2008 ACM Symp. Appl. Comput. - SAC '08*, p. 1353, 2008.
- [81] C. Mettouris and G. A. Papadopoulos, “LNCS 7652 - Contextual Modelling in Context-Aware Recommender Systems: A Generic Approach,” *LNCS*, vol. 7652, pp. 41–52, 2011.
- [82] M. Unger, “Latent Context-Aware Recommender Systems,” *AAAI Tech. Rep. WS-99-01.*, pp. 383–386, 2015.
- [83] G. Adomavicius and A. Tuzhilin, “Context-aware recommender systems,” in *Recommender Systems Handbook, Second Edition*, 2015, pp. 191–226.
- [84] F. Buttussi and L. Chittaro, “MOPET: A context-aware and user-adaptive wearable system for fitness training,” *Artif. Intell. Med.*, 2008.
- [85] Y. Zhang and L. Wang, “Some challenges for context-aware recommender systems,” in *ICCSE 2010 - 5th International Conference on Computer Science and Education, Final Program and Book of Abstracts*, 2010.
- [86] C. A. Gomez-Uribe and N. Hunt, “The Netflix Recommender System,” *ACM Trans. Manag. Inf. Syst.*, 2015.
- [87] G. Adomavicius, R. Sankaranarayanan, S. Sen, and A. Tuzhilin, “Incorporating contextual information in recommender systems using a multidimensional approach,” *ACM Trans. Inf. Syst.*, vol. 23, no. 1, pp. 103–145, Jan. 2005.
- [88] J. Hong, E. Suh, and S.-J. Kim, “Context-aware systems: A literature review and classification,” *Expert Syst. Appl.*, vol. 36, no. 4, pp. 8509–8522, May 2009.
- [89] S. Mika, “Challenges for nutrition recommender systems,” in *CEUR Workshop Proceedings*, 2011.
- [90] R. Devi, J. Powell, and S. Singh, “A web-based program improves physical activity outcomes in a primary care angina population: Randomized controlled trial,” *J. Med. Internet Res.*, 2014.
- [91] L. Van Genugten, P. Van Empelen, and A. Oenema, “Intervention use and action planning in a web-based computer-tailored weight management program for overweight adults: Randomized controlled trial,” *J. Med. Internet Res.*, vol. 16, no. 7, 2014.
- [92] K. M. Carpenter, J. C. Lovejoy, J. M. Lange, J. E. Hapgood, and S. M. Zbikowski, “Outcomes and utilization of a low intensity workplace weight loss program,” *J. Obes.*, vol. 2014, 2014.
- [93] M. Ge, F. Ricci, and D. Massimo, “Health-aware Food Recommender System,” *Proc. 9th ACM Conf. Recomm. Syst.*, pp. 333–334, 2015.
- [94] G. Cerón-Rios, D. M. López, and B. Blobel, *Architecture and user-context models of cocare: A context-aware mobile recommender system for health*

- promotion*, vol. 237. 2017.
- [95] C. Y. Wang, Y. H. Wu, and S. C. T. Chou, "Toward a ubiquitous personalized daily-life activity recommendation service with contextual information: A services science perspective," *Inf. Syst. E-bus. Manag.*, 2010.
 - [96] H. Du, G. M. Youngblood, and P. Pirolli, "Efficacy of a smartphone system to support groups in behavior change programs," in *Proceedings - Wireless Health 2014, WH 2014*, 2014.
 - [97] "(PDF) Mobile Personal Health Application for Empowering Diabetic Patients: The Case within EMPOWER Project." [Online]. Available: https://www.researchgate.net/publication/262767570_Mobile_Personal_Health_Application_for_Empowering_Diabetic_Patients_The_Case_within_EMPOWER_Project. [Accessed: 03-Nov-2019].
 - [98] J. Chuang *et al.*, "DiabeticLink: An integrated and intelligent cyber-enabled health social platform for diabetic patients," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2014, vol. 8549 LNCS, pp. 63–74.
 - [99] I.-D. Torres Pardo, *A MOBILE RECOMMENDER OF PHYSICAL ACTIVITY TO PREVENT AND CONTROL CHRONIC NON-COMMUNICABLE DISEASES.* .
 - [100] A. Abbas, M. Ali, M. U. Shahid Khan, and S. U. Khan, "Personalized healthcare cloud services for disease risk assessment and wellness management using social media," *Pervasive Mob. Comput.*, vol. 28, pp. 81–99, Jun. 2016.
 - [101] C. Rico Olarte, E. J. Girón Buitrón, G. M. Cerón Ríos, and D. M. López Gutiérrez, "Towards a Standardized User Model for Personalized Systems in Health," *Sist. y Telemática*, vol. 13, no. 34, pp. 9–29, Sep. 2015.
 - [102] K. X. González, M. Á. Carvajal, G. M. Cerón, and D. M. López, "Modelado de un sistema consciente del contexto para soportar intervenciones en actividad física y nutrición saludable Modeling of a context-aware system to support interventions in physical activities and healthy nutrition," vol. 15, no. 28, pp. 173–196, 2016.
 - [103] E. J. G. Buitron, G. M. C. Rios, C. R. Olarte, and D. M. L. Gutierrez, "Framework for data model to personalized health systems," in *2016 8th Euro American Conference on Telematics and Information Systems, EATIS 2016*, 2016.
 - [104] J. L. Jorro-Aragoneses, G. M. Ceron-Rios, M. B. Diaz-Agudo, J. A. Recio-Garcia, and D. M. Lopez-Gutierrez, "RecOnto: An Ontology to Model Recommender Systems and its Components," in *2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI)*, 2017, pp. 815–821.
 - [105] G. M. Cerón-Rios, D. M. Lopez-Gutierrez, B. Díaz-Agudo, and J. A. Recio-García, "Recommendation System based on CBR algorithm for the Promotion of Healthier Habits," 2017.
 - [106] J. armando Ordoñez, "Smart platform of recommendation in social networks for education in habits, lifestyles and physical exercise for a patient with diabetes.," in *Laccei International Multi-Conference*, 2017.
 - [107] J. M. Gomez-Perez, M. Grobelnik, C. Ruiz, M. Tilly, and P. Warren, "Using task context to achieve effective information delivery," in *ACM International*

- Conference Proceeding Series*, 2009.
- [108] K. Antypas and S. C. Wangberg, "An Internet- and Mobile-Based Tailored Intervention to Enhance Maintenance of Physical Activity After Cardiac Rehabilitation: Short-Term Results of a Randomized Controlled Trial," *J. Med. Internet Res.*, vol. 16, no. 3, p. e77, Mar. 2014.
- [109] R. Hervás, J. Bravo, and J. Fontecha, "A Context Model based on Ontological Languages: a Proposal for Information Visualization."
- [110] T. Lovett, "Sensing and Interactive Intelligence in Mobile Context Aware Systems," 2012.
- [111] C. Bauer Sarah Spiekermann, "Association for Information Systems AIS Electronic Library (AISeL) CONCEPTUALIZING CONTEXT FOR ADAPTIVE PERVASIVE COMMERCE Recommended Citation," 2011.
- [112] K. Antypas and S. C. Wangberg, "An Internet- and mobile-based tailored intervention to enhance maintenance of physical activity after cardiac rehabilitation: short-term results of a randomized controlled trial.," *J. Med. Internet Res.*, vol. 16, no. 3, p. e77, Mar. 2014.
- [113] C. Buntrock *et al.*, "Evaluating the efficacy and cost-effectiveness of web-based indicated prevention of major depression: Design of a randomised controlled trial," *BMC Psychiatry*, vol. 14, no. 1, Jan. 2014.
- [114] "Diseño centrado en el usuario," *Rev. Q*, 2017.
- [115] S. Design, "User-centered design," *Web Style Guid.*, 2004.
- [116] Y. Terziev, M. Benner-Wickner, T. Brückmann, and V. Gruhn, "Ontology-based recommender system for information support in knowledge-intensive processes," 2015.
- [117] S. Ajmani, H. Ghosh, A. Mallik, and S. Chaudhury, "An Ontology Based Personalized Garment Recommendation System," in *2013 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)*, 2013, pp. 17–20.
- [118] M. A. ALVAREZ and C. YAN, "A GRAPH-BASED SEMANTIC SIMILARITY MEASURE FOR THE GENE ONTOLOGY," *J. Bioinform. Comput. Biol.*, vol. 09, no. 06, pp. 681–695, Dec. 2011.
- [119] S. Alhazbi, L. Lotfi, R. Ali, and R. Suwailih, "An Ontology-Based Context-Aware Mobile System for On-the-Move Tourists," Springer, Cham, 2013, pp. 252–256.
- [120] C. Villalonga *et al.*, "Ontology-Based High-Level Context Inference for Human Behavior Identification," *Sensors*, vol. 16, no. 10, p. 1617, Sep. 2016.
- [121] L. Zhuhadar, O. Nasraoui, and R. Wyatt, "Visual Ontology-Based Information Retrieval System," *2009 13th Int. Conf. Inf. Vis.*
- [122] M. Lanzenberger, J. J. Sampson, M. Rester, Y. Naudet, and T. Latour, "Visual ontology alignment for knowledge sharing and reuse," *J. Knowl. Manag.*, vol. 12, no. 6, pp. 102–120, Oct. 2008.
- [123] L. Orbst, T. Janssen, and W. (Werner) Ceusters, *Ontologies and semantic technologies for intelligence*. IOS Press, 2010.
- [124] N. Weißenberg, "Ontology Architecture for Semantic Geo Services for Olympia 2008 *."
- [125] S. Borgo and P. Leitão, "Foundations for a Core Ontology of

- Manufacturing,” 2007, pp. 751–775.
- [126] “Taxonomy of DOLCE basic categories (Masolo et al., 2003). | Download Scientific Diagram.” [Online]. Available: https://www.researchgate.net/figure/Taxonomy-of-DOLCE-basic-categories-Masolo-et-al-2003_fig1_226253278. [Accessed: 21-May-2019].
- [127] L. Solano, G. Dirigida, P. Rosado, C. Fernando, and R. Subirón, “Definición de una ontología integrada de procesos y recursos, para el desarrollo colaborativo de planes de proceso TESIS DOCTORAL.”
- [128] P. Gokhale, S. Deokattey, and K. Bhanumurthy, “Ontology Development Methods,” *DESIDOC J. Libr. Inf. Technol.*, vol. 31, no. 2, pp. 77–83, Mar. 2011.
- [129] A. Al-Arfaj and A. Al-Salman, “Towards Ontology Construction from Arabic Texts-A Proposed Framework,” in *2014 IEEE International Conference on Computer and Information Technology*, 2014, pp. 737–742.
- [130] M. Montes-y-Gómez, H. J. Escalante, A. Segura, and J. de D. Murillo, *Advances in artificial intelligence -- IBERAMIA 2016: 15th Ibero-American Conference on AI, San José, Costa Rica, November 23-25, 2016, Proceedings*.
- [131] R. Subhashini and J. Akilandeswari, “A survey on ontology construction methodologies,” *Int. J. Enterp. Comput. Bus. Syst.*, vol. 1, no. 1, pp. 1–14, 2011.
- [132] BioPortal Ontologies, “National Cancer Institute Thesaurus - Systematized Nomenclature of Medicine - Classes | NCBO BioPortal.” [Online]. Available: <https://bioportal.bioontology.org/ontologies/NCIT?p=classes&conceptid=http://ncicb.nci.nih.gov/xml/owl/EVS/Thesaurus.owl#C53489>. [Accessed: 21-May-2019].
- [133] BioPortal Ontologies, “Basic Formal Ontology - Summary | NCBO BioPortal.” [Online]. Available: <https://bioportal.bioontology.org/ontologies/BFO>. [Accessed: 21-May-2019].
- [134] M. Gaeta, F. Orciuoli, S. Paolozzi, and S. Salerno, “Ontology Extraction for Knowledge Reuse: The e-Learning Perspective,” *IEEE Trans. Syst. Man, Cybern. - Part A Syst. Humans*, vol. 41, no. 4, pp. 798–809, Jul. 2011.
- [135] S. De Evolucion De Ontologías, P. La, and G. De, “PONTIFICIA UNIVERSIDAD JAVERIANA FACULTAD DE INGENIERIA INGENIERIA DE SISTEMAS.”
- [136] “SNOMED - 5-Step Briefing.” [Online]. Available: <http://www.snomed.org/snomed-ct/five-step-briefing>. [Accessed: 21-May-2019].
- [137] H. Kim, J. Mentzer, and R. Taira, “Developing a Physical Activity Ontology to Support the Interoperability of Physical Activity Data.,” *J. Med. Internet Res.*, vol. 21, no. 4, p. e12776, Apr. 2019.
- [138] G. Cerón-Rios, D. M. López, and B. Blobel, “Architecture and User-Context Models of CoCare: A Context-Aware Mobile Recommender System for Health Promotion.,” *Stud. Health Technol. Inform.*, vol. 237, pp. 140–147, 2017.
- [139] K. X. González, M. Á. Carvajal, G. M. Cerón, and D. M. López, “Modelado de un sistema consciente del contexto para soportar intervenciones en actividad física y nutrición saludable,” *Rev. Ing. Univ. Medellín*, vol. 15, no. 28, pp. 173–

- 196, 2016.
- [140] L. Liu, F. Lecue, N. Mehandjiev, and L. Xu, "Using context similarity for service recommendation," in *Proceedings - 2010 IEEE 4th International Conference on Semantic Computing, ICSC 2010*, 2010, pp. 277–284.
 - [141] F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, *Recommender Systems Handbook*, vol. 53, no. 9. 2011.
 - [142] X. Liu and K. Aberer, "SoCo: A social network aided context-aware recommender system," in *WWW 2013 - Proceedings of the 22nd International Conference on World Wide Web*, 2013.
 - [143] U. Panniello, A. Tuzhilin, M. Gorgoglione, C. Palmisano, and A. Pedone, "Experimental comparison of pre- vs. post-filtering approaches in context-aware recommender systems," in *RecSys'09 - Proceedings of the 3rd ACM Conference on Recommender Systems*, 2009, pp. 265–268.
 - [144] A. Ruiz Iniesta, "Aplicación de estrategias de recomendación a la localización personalizada de recursos educativos," 2014.
 - [145] D. Jannach, M. Zanker, A. Felfernig, and G. Friedrich, *Recommender systems: An introduction*, vol. 9780521493369. Cambridge University Press, 2010.
 - [146] C. C. Aggarwal, "An Introduction to Recommender Systems," in *Recommender Systems*, Cham: Springer International Publishing, 2016, pp. 1–28.
 - [147] R. Burke, "Hybrid recommender systems: Survey and experiments," *User Model. User-Adapted Interact.*, vol. 12, no. 4, pp. 331–370, 2002.
 - [148] J. Sauro, "Measuring Usability With The System Usability Scale (SUS)," *Meas. Usability*, pp. 1–5, 2011.
 - [149] ISO, "Usabilidad," 2013. [Online]. Available: <https://iso25000.com/index.php/normas-iso-25000/iso-25010/23-usabilidad>. [Accessed: 03-Dec-2019].
 - [150] E. Sepg and D. Zubrow, "Measuring Software Product Quality: the ISO 25000 Series and CMMI," 2004.
 - [151] "Ver proyecto | Departamento de Telemática." [Online]. Available: http://web.unicauca.edu.co/telematica/?q=telematica/ver_proyecto/13. [Accessed: 01-Dec-2019].

ANEXO A

Este anexo contiene el análisis exploratorio de las variables, el análisis del modelo de minería, y la descripción genérica de las herramientas usadas para tal fin.

A.1. Análisis exploratorio de datos

El análisis de las variables está dividido en tres actividades definidas así: primero, la calidad de los atributos; segundo, la relación entre los atributos y la clase objetivo; por último, el análisis multivariable.

A.1.1. Calidad de los atributos

Este primer análisis busca encontrar el nivel de correlación entre los atributos del *dataset* que no corresponden a la clase objetivo, identificar datos faltantes o información de poca utilidad. Después del análisis, en primera instancia no se encuentra una correlación directa entre los atributos del *dataset* ni datos faltantes o de poca utilidad. La figura E.1 muestra la distribución de datos entre los atributos de uso del sistema y enfermedad cardiovascular; para la mayoría de los atributos se presenta un comportamiento de distribución parecido, indicando que cada valor de un atributo existe en todos los valores de otro atributo cualquiera, esto es esperado ya que el *dataset* se conforma de todas las combinaciones posibles entre los atributos.

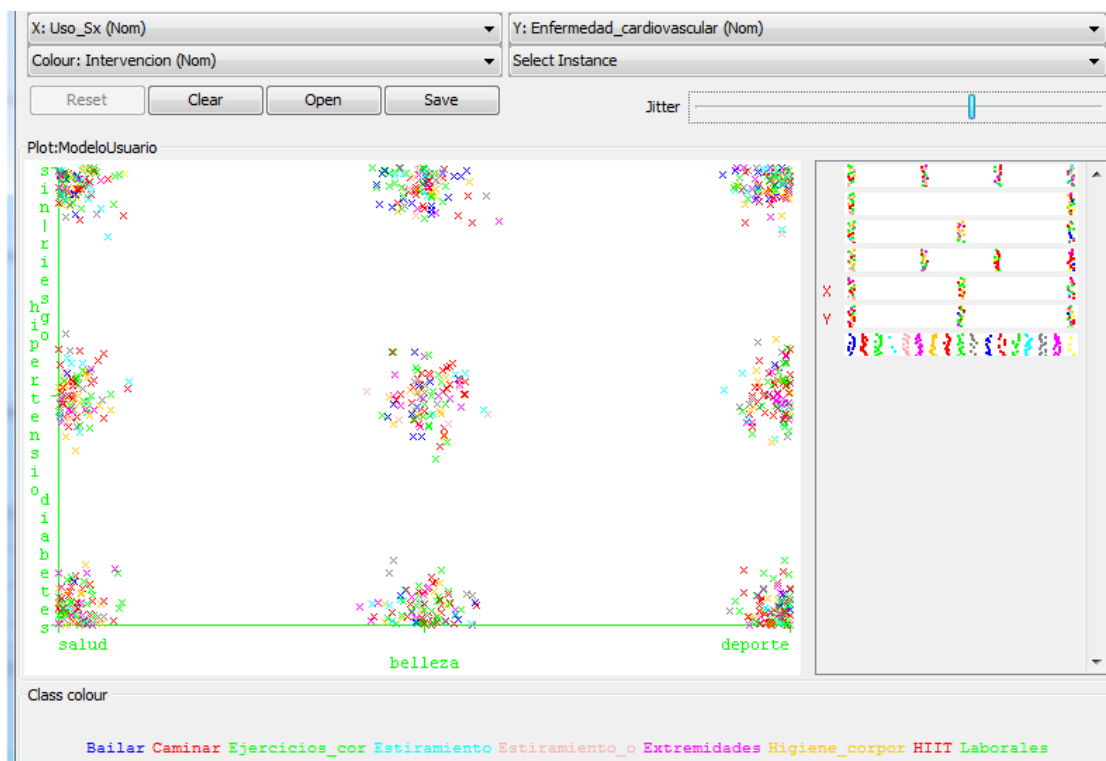


Figura E.1. Distribución de variables entre Uso_Sx vs Enfermedad_cardiovascular

A.1.2. Relación entre atributos y la clase objetivo

Este análisis ofrece información preliminar sobre el comportamiento de los atributos individualmente con la clase objetivo.

IMC vs Intervenciones

El análisis de estas dos variables presenta una gran variedad de oportunidades de intervención para un determinado IMC, aunque existen casos de mayor éxito de una intervención a partir de un valor de IMC, los porcentajes son muy cercanos. Analizando la vista contraria, es posible apreciar que algunas intervenciones solo se presentan bajo una variable del IMC, es decir que algunas intervenciones nunca se presentaran para un determinado valor de IMC, por ejemplo, si observamos solo estas dos variables, cuando el IMC sea obesidad, nunca se podrá recomendar el grupo de intervención trotar, incluso esta intervención solamente se podrá recomendar cuando el IMC sea exclusivamente bajo_peso. El IMC si bien no provee una inclinación

representativa hacia alguna intervención específica, es claro que si puede convertirse en un filtro para intervenciones que no pueden existir para valores específicos del IMC.

Etnia vs Intervenciones

El análisis indica que la variable Etnia tiene una distribución parcial en las intervenciones, esto indica que no existen grandes restricciones de intervención para una determinada etnia. Para la variable Uso_Sx se encuentra el mismo comportamiento anteriormente mencionado.

Traumatismo vs Intervenciones

Los porcentajes de aparición indican que la variable traumatismo puede igualmente ser un filtro de intervenciones en determinado momento, lo anterior dado que existen porcentajes con valor del 0% de aparición de una intervención para algún traumatismo específico.

Ciclo de vida vs Intervenciones

Los porcentajes sugieren que las intervenciones correspondientes a estiramientos de cualquier tipo y ejercicios de relajación se orientan hacia los adolescentes_adultos, mientras que las intervenciones laborales en general se orientan a los adultos. Para los demás grupos de intervenciones se expresan distribuciones similares para adultos o adolescentes.

Enfermedad cardiovascular vs Intervenciones

Esta última variable muestra que para las intervenciones que requieren cierta capacidad de resistencia cardiovascular, la recomendación de ellas se hará cuando el usuario no tenga riesgo de alguna enfermedad cardiovascular.

A.1.3. Análisis multivariantes

En este punto son analizados los atributos de interés dado el análisis del anterior punto. Para este estudio se analizan las variables IMC vs Traumatismo, dado que ambos presentan un comportamiento de filtro en la elección de intervenciones. Mediante la herramienta *RapidMiner* se analizan como primera medida el IMC vs Traumatismo. La figura E.2 arroja el resultado de comparar las dos variables en la herramienta.




Figura E.2. Distribución de IMC vs Traumatismo

La anterior figura indica que para cada valor de IMC, existe al menos un valor de alguna opción de traumatismo. Esta conclusión ya se había contemplado en los análisis preliminares realizados en la herramienta *Weka*. Ya que las variables son en el análisis exploratorio de los datos consideradas condicionales importantes en el modelo, se analiza ahora cual es el comportamiento esperado de la distribución de intervenciones dada las variables del IMC y Traumatismo. La figura E.3 muestra los resultados en la herramienta *RapidMiner* del cruce de las tres variables.





Figura E.3. Distribución de IMC vs Traumatismo vs Intervenciones

La figura E.3 indica que dada las dos primeras variables, algunas intervenciones solo pueden existir en determinados contextos. En principio, desde el punto de vista de analista de datos, este patrón debe ser revisado dado que agrupa ciertas intervenciones a posibilidades específicas de las naturalezas del IMC y Traumatismo, esto puede desequilibrar el modelo en su creación, sin embargo como experto en el Modelo de Usuario es comprensible el comportamiento presente, dado que no todas las intervenciones pueden ser presentadas a los usuarios dada alguna representación de sus variables de IMC y Traumatismo.

ANEXO B**B1. Evaluación – Escala de satisfacción**

Califique de 1 a 5 los siguientes enunciados (encierre con un círculo). Tenga en cuenta que 1 es la calificación más baja (completamente en desacuerdo) y 5 la calificación más alta (completamente de acuerdo).

1. ¿Qué tan a gusto se sintió utilizando la aplicación? (Fácil de utilizar)



1



2



3




4



5

2. ¿Cuánto cree que podría mejorar su calidad de vida al utilizar la aplicación frecuentemente?



1



2



3




4



5

3. ¿Qué tan satisfecho lo deja la aplicación con respecto al apoyo para la promoción de actividad física y dieta saludable de manera personalizada?



1



2



3




4




5

4. ¿Cómo se sentiría recomendando la aplicación a sus conocidos?



5. ¿Recomendaría esta aplicación?



B2. Resultados del estudio de caso

Este anexo contiene las tablas y figuras que sirven de soporte a los resultados obtenidos en la aplicación del estudio de caso. Las tablas corresponden a las métricas de usabilidad y las figuras hacen parte de los resultados de las variables de eficiencia y rendimiento.

Métrica	Funciones	Porcentaje	Observaciones
Funciones evidentes	Ver tarjetas de información	100%	Función completamente evidente al usuario.
	Ir a la recomendación del día	100%	Función completamente evidente al usuario.
	Ir a la recomendación de ayer	100%	Función completamente evidente al usuario.
	Ir a inicio	0%	Ningún usuario tuvo la necesidad de realizar esta actividad por dos razones: 1. El aprendizaje de la navegación en la página (desplazamiento o scroll) 2. Debido al hilo conductor del estudio de caso.
	Registrarse	100%	Función completamente evidente al usuario.
	Acceder a la cuenta	100%	Función completamente evidente al usuario.
	Configurar perfil	70%	Los usuarios no identificaron tan rápido la opción de configuración. Se deben realizar unos ajustes (texto explicativo, ampliación de imagen) en la presentación de esta opción.
	Conocerte	100%	Función completamente evidente al usuario.
	Recomendarte	100%	Función completamente evidente al usuario.
	Ver video	100%	Función completamente evidente al usuario.
Calificar video	50%	Esta función tiene tal porcentaje de evidencia debido a que: 1. La ubicación del elemento respecto a donde el	

Métrica	Funciones	Porcentaje	Observaciones
			usuario enfoca su atención en el momento. 2. Falta de texto explicativo o señalización.
	Visitar recomendaciones vistas	90%	Es recomendable cambiar la ubicación del botón o indicar dicha ubicación.
	Salir	100%	Función completamente evidente al usuario.
Total		85%	El promedio de certeza de las funciones de la métrica se da por dos razones: 1. Algunas funciones evidentes deben ser mejoradas para que el usuario las identifique con mayor rapidez y precisión, 2. De acuerdo al estudio de caso aplicado, una de estas funciones no fue necesaria de utilizar. Se determina que es un buen porcentaje de certeza en cuanto a lo evidente que es una función de la aplicación web implementada.

Tabla B.1a. Análisis por funciones de la métrica funciones evidentes

Métrica	Orden participantes	Medida	Observaciones
Funciones evidentes	1°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones evidentes, el participante N° 1 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none">- Ir a inicio- Calificar video
	2°	$X = A/B = 10/13 = 0,77$ 77%	De las 13 funciones evidentes, el participante N° 2 identifico 10 funciones. Las funciones no identificadas son: <ul style="list-style-type: none">- Ir a inicio- Configurar perfil- Visitar recomendaciones vistas
	3°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones evidentes, el participante N° 3 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none">- Ir a inicio- Calificar video

Métrica	Orden participantes	Medida	Observaciones
	4°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones evidentes, el participante N° 4 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none"> - Ir a inicio - Calificar video
	5°	$X = A/B = 12/13 = 0,92$ 92%	De las 13 funciones evidentes, el participante N° 5 identifico 12 funciones. La función no identificada es: <ul style="list-style-type: none"> - Ir a inicio
	6°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones evidentes, el participante N° 6 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none"> - Ir a inicio - Configurar perfil
	7°	$X = A/B = 10/13 = 0,77$ 77%	De las 13 funciones evidentes, el participante N° 7 identifico 10 funciones. Las funciones no identificadas son: <ul style="list-style-type: none"> - Ir a inicio - Configurar perfil - Calificar video
	8°	$X = A/B = 12/13 = 0,92$ 92%	De las 13 funciones evidentes, el participante N° 8 identifico 12 funciones. La función no identificada es: <ul style="list-style-type: none"> - Ir a inicio
	9°	$X = A/B = 12/13 = 0,92$ 92%	De las 13 funciones evidentes, el participante N° 9 identifico 12 funciones. La función no identificada es: <ul style="list-style-type: none"> - Ir a inicio
	10°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones evidentes, el participante N° 10 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none"> - Ir a inicio - Calificar video
Total		85%	El promedio de evidencia de las funciones de la métrica coincide con el promedio de certeza en el comportamiento de los usuarios con respecto a la métrica, que coincide con la tabla anterior, confirmando así la tendencia de

Métrica	Orden participantes	Medida	Observaciones
			los usuarios a reconocer una función del sistema como evidente o no.

Tabla B.1b. Análisis por participante de la métrica funciones evidentes

Métrica	Funciones	Porcentaje	Observaciones
Funciones fáciles de comprender	Identificar objetivo de la aplicación	100%	Función completamente fácil de comprender para el usuario.
	Identificar la recomendación del día	100%	Función completamente fácil de comprender para el usuario.
	Identificar la recomendación de ayer	100%	Función completamente fácil de comprender para el usuario.
	Llenar formulario de registro	100%	Función completamente fácil de comprender para el usuario.
	Llenar formulario de acceso	100%	Función completamente fácil de comprender para el usuario.
	Identificar el área de perfil	100%	Función completamente fácil de comprender para el usuario, sin embargo, es necesario una mayor señalización del área del perfil.
	Acceder a las opciones del menú configuración	90%	Los usuarios no identificaron tan rápido la opción de configuración. Se deben realizar unos ajustes (texto explicativo, ampliación de imagen) en la presentación de esta opción.
	Cerrar cuenta	80%	Es una función que, en el estudio de caso aplicado, depende de la operación cambiar contraseña.
Llenar formulario de conoerte	100%	Función completamente fácil de comprender para el usuario.	

Métrica	Funciones	Porcentaje	Observaciones
	Activar personalización	100%	Función completamente fácil de comprender para el usuario.
	Identificar elementos de video	90%	Esta función tiene tal porcentaje de evidencia debido a que un caso particular simplemente pasó por alto los elementos.
	Identificar niveles de calificación	60%	Esta función tiene tal porcentaje de comprensión debido a que: 1. La ubicación del elemento respecto a donde el usuario enfoca su atención en el momento. 2. Falta de texto explicativo o señalización.
	Identificar el área de recomendaciones vistas	90%	Es recomendable cambiar la ubicación del botón o indicar dicha ubicación.
	Total	93%	El promedio de comprensión de las funciones de la métrica se da porque algunas funciones fáciles de comprender deben ser mejoradas para que el usuario las identifique con mayor rapidez y precisión. Se determina que es un muy buen porcentaje de fácil comprensión de una función de la aplicación web implementada.

Tabla B.2a. Análisis por funciones de la métrica funciones fáciles de comprender

Métrica	Orden participantes	Medida	Observaciones
Funciones fáciles de comprender	1°	$X = A/B = 13/13 = 1$ 100%	De las 13 funciones fáciles de comprender, el participante N° 1 identifico todas las 13 funciones.
	2°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones fáciles de comprender, el participante N° 2 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none"> - Acceder a las opciones del menú configuración - Identificar el área de recomendaciones vistas

Métrica	Orden participantes	Medida	Observaciones
	3°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones fáciles de comprender, el participante N° 3 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none">- Identificar elementos de video- Identificar niveles de calificación
	4°	$X = A/B = 11/13 = 0,85$ 85%	De las 13 funciones fáciles de comprender, el participante N° 4 identifico 11 funciones. Las funciones no identificadas son: <ul style="list-style-type: none">- Cerrar cuenta- Identificar niveles de calificación
	5°	$X = A/B = 13/13 = 1$ 100%	De las 13 funciones fáciles de comprender, el participante N° 1 identifico todas las 13 funciones.
	6°	$X = A/B = 13/13 = 1$ 100%	De las 13 funciones fáciles de comprender, el participante N° 1 identifico todas las 13 funciones.
	7°	$X = A/B = 12/13 = 0,92$ 92%	De las 13 funciones fáciles de comprender, el participante N° 7 identifico 12 funciones. La función no identificada es: <ul style="list-style-type: none">- Identificar niveles de calificación
	8°	$X = A/B = 13/13 = 1$ 100%	De las 13 funciones fáciles de comprender, el participante N° 1 identifico todas las 13 funciones.
	9°	$X = A/B = 12/13 = 0,92$ 92%	De las 13 funciones fáciles de comprender, el participante N° 9 identifico 12 funciones. La función no identificada es: <ul style="list-style-type: none">- Cerrar cuenta
	10°	$X = A/B = 12/13 = 0,92$ 92%	De las 13 funciones fáciles de comprender, el participante N° 10 identifico 12 funciones. Las funciones no identificadas son: <ul style="list-style-type: none">- Identificar niveles de calificación
Total		93%	El promedio de la facilidad de comprensión de las funciones de la métrica coincide con el promedio de fácil comprensión de los usuarios con respecto a la métrica, que coincide con la tabla anterior, confirmando así la tendencia de los usuarios a

Métrica	Orden participantes	Medida	Observaciones
			reconocer una función del sistema como fácil de comprender o no.

Tabla B.2b. Análisis por participante de la métrica funciones fáciles de comprender

Métrica	Operaciones	Porcentaje	Observaciones
Facilidad para cancelar una operación	Registrarse	0%	Ningún usuario tuvo la necesidad de realizar esta actividad pues es una función completamente evidente al usuario, donde la facilidad de comprensión de la función (llenar el formulario de registro) es del 100%.
	Acceder a la cuenta	60%	La mayoría de usuarios tuvieron la necesidad de realizar esta actividad dado que las instrucciones del estudio de caso aplicado, llevaba a los usuarios a realizar la función. Sin embargo cabe resaltar que la función es completamente evidente para el usuario y fácil de comprender.
	Cambiar avatar	80%	El porcentaje presentado con respecto a esta función se debe a que no todos los usuarios utilizaron la operación 'cambiar avatar' dentro de la aplicación, pues en el estudio de caso la tarea no fue descrita explícitamente.
	Cambiar color	50%	El porcentaje presentado con respecto a esta función se debe a que la mitad de los usuarios utilizaron la operación 'cambiar color' dentro de la aplicación, pues en el estudio de caso la tarea no fue descrita explícitamente.
	Cambiar configuraciones de cuenta (contraseña)	70%	El porcentaje presentado con respecto a esta función se debe a que la mayoría de los usuarios utilizaron la operación 'cambiar contraseña' dentro de la aplicación, que aunque fue descrita explícitamente en las instrucciones para el estudio de caso, algunos usuarios pasaron por alto dicha instrucción.
	Vista previa de perfil	10%	El porcentaje presentado con respecto a esta función se debe a uno de los usuarios quien identificó la operación dentro de la aplicación, a pesar de que en el estudio de caso la tarea no fue descrita explícitamente.

Métrica	Operaciones	Porcentaje	Observaciones
	Conocerte	70%	La mayoría de usuarios realizaron esta actividad debido a que la operación de cancelación de la función era evidente y los usuarios en su forma de navegar así lo hicieron. Sin embargo cabe resaltar que la función es completamente evidente para el usuario.
	Calificar	60%	La mayoría de usuarios realizaron esta actividad debido a la correcta identificación de los niveles de calificación, la cual tiene un porcentaje de fácil comprensión del 60% también.
Total		50%	El promedio de cancelación de las operaciones definidas por la métrica es determinado como aceptable. Entonces, es importante determinar dos condiciones para la calificación de esta métrica: la necesidad y la claridad. Muchas operaciones no necesitaron ser canceladas por parte de los usuarios, pero las operaciones que fueron canceladas, la cancelación se hizo con facilidad debido a la claridad de los elementos de dichas operaciones.

Tabla B.3a. Análisis de operaciones de la métrica facilidad para cancelar una operación

Métrica	Orden participantes	Medida	Observaciones
Facilidad para cancelar una operación	1°	$X = A/B = 2/8 = 0,25$ 25%	De las 8 operaciones fáciles de cancelar, el participante N° 1 solo tuvo necesidad de cancelar 2 funciones: <ul style="list-style-type: none"> - Cambiar configuraciones de cuenta (contraseña) - Calificar
	2°	$X = A/B = 5/8 = 0,63$ 63%	De las 8 operaciones fáciles de cancelar, el participante N° 2 tuvo necesidad de cancelar 5 funciones: <ul style="list-style-type: none"> - Acceder a la cuenta - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña) - Calificar

Métrica	Orden participantes	Medida	Observaciones
	3°	$X = A/B = 4/8 = 0,5$ 50%	De las 8 operaciones fáciles de cancelar, el participante N° 3 tuvo necesidad de cancelar 4 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña) - Conocer
	4°	$X = A/B = 2/8 = 0,25$ 25%	De las 8 operaciones fáciles de cancelar, el participante N° 4 solo tuvo necesidad de cancelar 2 funciones: <ul style="list-style-type: none"> - Acceder a la cuenta - Conocer
	5°	$X = A/B = 5/8 = 0,63$ 63%	De las 8 operaciones fáciles de cancelar, el participante N° 5 tuvo necesidad de cancelar 5 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña) - Vista previa de perfil - Calificar
	6°	$X = A/B = 4/8 = 0,5$ 50%	De las 8 operaciones fáciles de cancelar, el participante N° 6 tuvo necesidad de cancelar 4 funciones: <ul style="list-style-type: none"> - Acceder a la cuenta - Cambiar avatar - Conocer - Calificar
	7°	$X = A/B = 2/8 = 0,25$ 25%	De las 8 operaciones fáciles de cancelar, el participante N° 7 solo tuvo necesidad de cancelar 2 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Conocer

Métrica	Orden participantes	Medida	Observaciones
	8°	$X = A/B = 6/8 = 0,75$ 75%	De las 8 operaciones fáciles de cancelar, el participante N° 8 tuvo necesidad de cancelar 6 funciones: <ul style="list-style-type: none"> - Acceder a la cuenta - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña) - Conocer - Calificar
	9°	$X = A/B = 6/8 = 0,75$ 75%	De las 8 operaciones fáciles de cancelar, el participante N° 9 tuvo necesidad de cancelar 6 funciones: <ul style="list-style-type: none"> - Acceder a la cuenta - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña) - Conocer - Calificar
	10°	$X = A/B = 4/8 = 0,5$ 50%	De las 8 operaciones fáciles de cancelar, el participante N° 10 solo tuvo necesidad de cancelar 2 funciones: <ul style="list-style-type: none"> - Acceder a la cuenta - Cambiar avatar - Cambiar configuraciones de cuenta (contraseña) - Conocer
	Total	50%	El promedio de cancelación de las operaciones definidas por la métrica coincide con el promedio de cancelación de las operaciones por parte de los usuarios con respecto a la métrica, confirmando de esta manera la tendencia de los usuarios a necesitar cancelar una operación o no.

Tabla B.3b. Análisis de participantes de la métrica facilidad para cancelar una operación

Métrica	Operaciones	Porcentaje	Observaciones
Facilidad para deshacer una operación de usuario	Cambiar avatar	80%	El porcentaje presentado con respecto a esta función se debe a que no todos los usuarios utilizaron la operación 'cambiar avatar' dentro de la aplicación, pues en el estudio de caso la tarea no fue descrita explícitamente.
	Cambiar color	50%	El porcentaje presentado con respecto a esta función se debe a que la mitad de los usuarios utilizaron la operación 'cambiar color' dentro de la aplicación, pues en el estudio de caso la tarea no fue descrita explícitamente.
	Cambiar configuraciones de cuenta (contraseña)	80%	El porcentaje presentado con respecto a esta función se debe a que la mayoría de los usuarios utilizaron la operación 'cambiar contraseña' dentro de la aplicación, que aunque fue descrita explícitamente en las instrucciones para el estudio de caso, algunos usuarios pasaron por alto dicha instrucción.
Total		70%	El promedio de la facilidad para deshacer operaciones de usuario definidas por la métrica es determinado como aceptable. Sin embargo, es importante determinar dos condiciones para la calificación de esta métrica: la necesidad y la claridad. Muchas operaciones no necesitaron ser deshechas por parte de los usuarios, pero las operaciones que si lo fueron, el deshacerlas se hizo con facilidad debido a la claridad de los elementos de dichas operaciones.

Tabla B.4a. Análisis de operaciones de la métrica facilidad para deshacer una operación de usuario

Métrica	Orden participantes	Medida	Observaciones
Facilidad para deshacer una operación	1°	$X = A/B = 1/3 = 0,33$ 33%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 1 solo tuvo necesidad de deshacer 1 función: - Cambiar configuraciones de cuenta (contraseña)

Métrica	Orden participantes	Medida	Observaciones
de usuario	2°	$X = A/B = 3/3 = 1$ 100%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 2 tuvo necesidad de deshacer las 3 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña)
	3°	$X = A/B = 3/3 = 1$ 100%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 3 tuvo necesidad de deshacer las 3 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña)
	4°	$X = A/B = 1/3 = 0,33$ 33%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 4 solo tuvo necesidad de deshacer 1 función: <ul style="list-style-type: none"> - Cambiar configuraciones de cuenta (contraseña)
	5°	$X = A/B = 3/3 = 1$ 100%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 5 tuvo necesidad de deshacer las 3 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña)
	6°	$X = A/B = 2/3 = 0,67$ 67%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 6 tuvo necesidad de deshacer 2 funciones: <ul style="list-style-type: none"> - Cambiar avatar - Cambiar configuraciones de cuenta (contraseña)
	7°	$X = A/B = 1/3 = 0,33$ 33%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 7 solo tuvo necesidad de deshacer 1 función:

Métrica	Orden participantes	Medida	Observaciones
			- Cambiar avatar
	8°	$X = A/B = 3/3 = 1$ 100%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 8 tuvo necesidad de deshacer las 3 funciones: - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña)
	9°	$X = A/B = 2/3 = 0,67$ 67%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 9 tuvo necesidad de deshacer 2 funciones: - Cambiar avatar - Cambiar color
	10°	$X = A/B = 2/3 = 0,67$ 67%	De las 3 operaciones de usuario fáciles de deshacer, el participante N° 10 tuvo necesidad de deshacer 2 funciones: - Cambiar avatar - Cambiar configuraciones de cuenta (contraseña)
Total		70%	El promedio de la facilidad de deshacer las operaciones definidas por la métrica coincide con el promedio de facilidad de deshacer las operaciones por parte de los usuarios con respecto a la métrica, confirmando de esta manera la tendencia de los usuarios a necesitar deshacer una operación o no.

Tabla B.4b. Análisis de participantes de la métrica facilidad para deshacer una operación de usuario

Métrica	Operaciones	Porcentaje	Observaciones
Personalización	Cambiar avatar	80%	El porcentaje presentado con respecto a esta función se debe a que no todos los usuarios utilizaron la operación 'cambiar avatar' dentro de la aplicación, pues en el estudio de caso la tarea no fue descrita explícitamente.

	Cambiar color	50%	El porcentaje presentado con respecto a esta función se debe a que la mitad de los usuarios utilizaron la operación 'cambiar color' dentro de la aplicación, pues en el estudio de caso la tarea no fue descrita explícitamente.
Total		65%	El promedio de la personalización de operaciones definidas por la métrica es determinado como aceptable; pero esto es debido a que dichas operaciones dentro del estudio de caso no fueron mostradas como tareas explícitas para realizar durante la prueba aplicada.

Tabla B.5a. Análisis de operaciones de la métrica personalización

Métrica	Orden participantes	Medida	Observaciones
Personalización	1°	$X = A/B = 0/2 = 0$ 0%	De las 2 operaciones que pueden ser personalizadas, el participante N° 1 no personalizó ninguna.
	2°	$X = A/B = 2/2 = 1$ 100%	De las 2 operaciones que pueden ser personalizadas, el participante N° 2 las personalizó ambas: - Cambiar avatar - Cambiar color
	3°	$X = A/B = 2/2 = 1$ 100%	De las 2 operaciones que pueden ser personalizadas, el participante N° 3 las personalizó ambas: - Cambiar avatar - Cambiar color
	4°	$X = A/B = 0/2 = 0$ 0%	De las 2 operaciones que pueden ser personalizadas, el participante N° 4 no personalizó ninguna.

Métrica	Orden participantes	Medida	Observaciones
	5°	$X = A/B = 2/2 = 1$ 100%	De las 2 operaciones que pueden ser personalizadas, el participante N° 5 las personalizó ambas operaciones: - Cambiar avatar - Cambiar color
	6°	$X = A/B = 1/2 = 0,5$ 50%	De las 2 operaciones que pueden ser personalizadas, el participante N° 6 personalizó 1 operación: - Cambiar avatar
	7°	$X = A/B = 1/2 = 0,5$ 50%	De las 2 operaciones que pueden ser personalizadas, el participante N° 7 personalizó 1 operación: - Cambiar avatar
	8°	$X = A/B = 2/2 = 1$ 100%	De las 2 operaciones que pueden ser personalizadas, el participante N° 8 las personalizó ambas operaciones: - Cambiar avatar - Cambiar color
	9°	$X = A/B = 2/2 = 1$ 100%	De las 2 operaciones que pueden ser personalizadas, el participante N° 9 las personalizó ambas operaciones: - Cambiar avatar - Cambiar color
	10°	$X = A/B = 1/2 = 0,5$ 50%	De las 2 operaciones que pueden ser personalizadas, el participante N° 7 personalizó 1 operación: - Cambiar avatar
Total		65%	El promedio de personalización de las operaciones definidas por la métrica coincide con el promedio de personalización de las operaciones por parte de los usuarios con respecto a la métrica, confirmando de esta manera la tendencia de los usuarios a personalizar una operación o no.

Tabla B.5b. Análisis de participantes de la métrica personalización

Métrica	Mensaje	Porcentaje	Observaciones
Claridad del mensaje	Usuario no registrado	40%	El porcentaje mostrado corresponde al porcentaje de usuarios que vieron el mensaje al acceder a una cuenta sin estar registrados. De todas maneras, la claridad del mensaje para dicho porcentaje de usuarios fue totalmente claro.
	Usuario registrado	100%	Todos los usuarios vieron el mensaje pues todos debían registrarse en la aplicación para acceder a su cuenta. Por lo tanto, la claridad del mensaje para dicho porcentaje de usuarios fue totalmente claro.
	Campo faltante en formulario de registro	10%	El porcentaje mostrado corresponde al porcentaje de usuarios que vieron el mensaje al llenar el formulario de registro de la aplicación. La claridad del mensaje para dicho porcentaje de usuarios fue totalmente claro. Cabe resaltar que llenar el formulario es una función completamente fácil de comprender para el usuario.
	Campo faltante de formulario de acceso	0%	Ningún usuario tuvo la necesidad de ver el mensaje al llenar el formulario de acceso a la aplicación. Sin embargo, es importante resaltar que llenar el formulario es una función completamente fácil de comprender para el usuario.
	Usuario y/o contraseña incorrectas	20%	El porcentaje corresponde al número de usuarios que visualizaron el mensaje. Se recomienda validar la contraseña en el registro, de todas maneras, el mensaje es 100% claro.
	Cambio de contraseña	70%	El porcentaje mostrado corresponde a la mayoría de usuarios que vieron el mensaje al cambiar la contraseña de su cuenta. La claridad del mensaje para dicho porcentaje de usuarios fue totalmente claro.
	Cambio de vista previa de perfil	0%	Ningún usuario tuvo la necesidad de ver el mensaje al llenar el formulario de acceso a la aplicación. Hay que tener en cuenta que la operación no era explícita dentro de la aplicación del estudio de caso.
	Campo faltante en formulario de conocerte	10%	El porcentaje corresponde al número de usuarios que visualizaron el mensaje. Se recomienda una operación que permita regresar al campo anterior del formulario.

Métrica	Mensaje	Porcentaje	Observaciones
	Calificación de la recomendación	40%	El porcentaje mostrado corresponde a una porción de usuarios que vieron el mensaje al calificar la recomendación. La claridad del mensaje para dicho porcentaje de usuarios fue totalmente claro.
	Total	32%	El promedio de claridad de los mensajes es del 100% en los casos en los que tales mensajes se presentaron para informar al usuario. El porcentaje mostrado corresponde a una porción de los mensajes mostrados de la totalidad de los mensajes de la aplicación.

Tabla B.6a. Análisis de mensajes de la métrica claridad de mensajes

Métrica	Orden participantes	Medida	Observaciones
Claridad de mensajes	1°	$X = A/B = 3/9 = 0,33$ 33%	De los 9 mensajes claros, el participante N° 1 visualizó 3 mensajes: <ul style="list-style-type: none"> - Usuario no registrado - Usuario registrado - Cambio de contraseña
	2°	$X = A/B = 4/9 = 0,44$ 44%	De los 9 mensajes claros, el participante N° 2 visualizó 4 mensajes: <ul style="list-style-type: none"> - Usuario no registrado - Usuario registrado - Usuario y/o contraseña incorrectas - Cambio de contraseña
	3°	$X = A/B = 2/9 = 0,22$ 22%	De los 9 mensajes claros, el participante N° 3 visualizó 2 mensajes: <ul style="list-style-type: none"> - Usuario no registrado - Cambio de contraseña
	4°	$X = A/B = 2/9 = 0,22$ 22%	De los 9 mensajes claros, el participante N° 4 visualizó 2 mensajes: <ul style="list-style-type: none"> - Usuario no registrado - Usuario registrado

Métrica	Orden participantes	Medida	Observaciones
	5°	$X = A/B = 3/9 = 0,33$ 33%	De los 9 mensajes claros, el participante N° 5 visualizó 3 mensajes: <ul style="list-style-type: none">- Usuario registrado- Cambio de contraseña- Calificación de la recomendación
	6°	$X = A/B = 3/9 = 0,33$ 33%	De los 9 mensajes claros, el participante N° 6 visualizó 3 mensajes: <ul style="list-style-type: none">- Usuario registrado- Cambio de contraseña- Calificación de la recomendación
	7°	$X = A/B = 3/9 = 0,33$ 33%	De los 9 mensajes claros, el participante N° 7 visualizó 3 mensajes: <ul style="list-style-type: none">- Usuario no registrado- Usuario registrado- Campo faltante en formulario de registro
	8°	$X = A/B = 4/9 = 0,44$ 44%	De los 9 mensajes claros, el participante N° 8 visualizó 4 mensajes: <ul style="list-style-type: none">- Usuario registrado- Cambio de contraseña- Campo faltante en formulario de conocerte- Calificación de la recomendación
	9°	$X = A/B = 3/9 = 0,33$ 33%	De los 9 mensajes claros, el participante N° 9 visualizó 3 mensajes: <ul style="list-style-type: none">- Usuario registrado- Usuario y/o contraseña incorrectas- Calificación de la recomendación
	10°	$X = A/B = 2/9 = 0,22$ 22%	De los 9 mensajes claros, el participante N° 10 visualizó 2 mensajes: <ul style="list-style-type: none">- Usuario registrado- Cambio de contraseña

Métrica	Orden participantes	Medida	Observaciones
Total		32%	El promedio de claridad de los mensajes es del 100% en los casos en los que tales mensajes se presentaron para informar al usuario. La claridad de los mensajes definidos por la métrica coincide con el promedio de claridad de los mensajes medido con los participantes con respecto a la métrica, confirmando así la tendencia de los usuarios a leer claramente los mensajes o no.

Tabla B.6b. Análisis de participantes de la métrica claridad de mensajes

Métrica	Elementos	Porcentaje	Observaciones
Claridad en los elementos de la interfaz	Tarjetas de información: 3	100%	Estos elementos de la interfaz son completamente claros para el usuario.
	Botones: 2 (Recomendación del día, Inicio)	65%	De estos elementos de interfaz, el de mayor uso fue el primer botón. El segundo botón no fue tan utilizado ya que la navegación por la página no hacía tan necesario su utilización. En cuanto a la claridad, ambos elementos fueron claros para el usuario.
	Enlaces: 2 (Recomendación del día, Recomendación de ayer)	95%	De estos elementos de interfaz, el primer enlace tuvo un porcentaje muy pequeño de menor utilización por parte de los usuarios, y esto es por la forma de navegación de cada usuario. La claridad de los elementos es total.
	Botones: 4 (Regístrate, Accede a cuenta, Registrar, Acceder)	100%	Estos elementos de la interfaz son completamente claros para el usuario.

Métrica	Elementos	Porcentaje	Observaciones
	Enlaces: 4 (Avatar, Color, Contraseña, Vista previa)	75%	De estos elementos de interfaz, los usuarios que los identificaron lo hicieron con claridad, sin embargo como algunos usuarios no identificaron tan rápido la opción de configuración, por ende no identificaron los elementos dentro de la opción y así se obtiene el resultado mostrado.
	Imagen con enlace: 1 (Configuración)	100%	Este elemento de la interfaz es completamente claro para el usuario.
	Botones: 2 (Conocerte, Aceptar)	100%	Estos elementos de la interfaz son completamente claros para el usuario.
	Tarjeta de información: 1 (Conocerte)	100%	Este elemento de la interfaz es completamente claro para el usuario.
	Botón: 1 (Recomiéndame)	100%	Este elemento de la interfaz es completamente claro para el usuario.
	Tarjeta de información: 1 (Recomiéndame)	100%	Este elemento de la interfaz es completamente claro para el usuario.
	Botón: 1 (Recomendaciones vistas)	80%	Este elemento de la interfaz no es completamente claro para el usuario. Es recomendable cambiar la ubicación del botón o indicar dicha ubicación.
	Botón: 1 (Salir)	100%	Este elemento de la interfaz es completamente claro para el usuario.
Total		92%	El promedio de claridad de los elementos de la interfaz se determina como muy bueno, dado que en los casos en los elementos no fueron totalmente identificados con claridad, el usuario aprendió su significado por la utilización de la plataforma. También se destaca la necesidad de utilizar algunos de los elementos, dado el estilo de navegación de algunos usuarios.

Tabla B.7a. Análisis de elementos de la métrica claridad en los elementos de la interfaz.

Métrica	Orden participantes	Medida	Observaciones
Claridad en los elementos de la interfaz	1°	$X = A/B = 21/23 = 0,91$ 91%	De los 23 elementos claros de la interfaz, el participante N° 1 dejó de visualizar 2 elementos: - Botón: Inicio - Botón: Recomendaciones vistas
	2°	$X = A/B = 21/23 = 0,91$ 91%	De los 23 elementos claros de la interfaz, el participante N° 2 dejó de visualizar 2 elementos: - Botón: Inicio - Botón: Recomendaciones vistas
	3°	$X = A/B = 23/23 = 1$ 100%	De los 23 elementos claros de la interfaz, el participante N° 3 no dejó de visualizar ningún elemento.
	4°	$X = A/B = 19/23 = 0,83$ 83%	De los 23 elementos claros de la interfaz, el participante N° 4 dejó de visualizar 4 elementos: - Enlace: Avatar - Enlace: Color - Enlace: Contraseña - Enlace: Vista previa
	5°	$X = A/B = 23/23 = 1$ 100%	De los 23 elementos claros de la interfaz, el participante N° 5 no dejó de visualizar ningún elemento.
	6°	$X = A/B = 17/23 = 0,74$ 74%	De los 23 elementos claros de la interfaz, el participante N° 6 dejó de visualizar 6 elementos: - Botón: Recomendación del día - Botón: Inicio - Enlace: Avatar - Enlace: Color - Enlace: Contraseña - Enlace: Vista previa
	7°	$X = A/B = 21/23 = 0,91$ 91%	De los 23 elementos claros de la interfaz, el participante N° 7 dejó de visualizar 2 elementos: - Enlace: Recomendación de ayer - Enlace: Vista previa
	8°	$X = A/B = 21/23 = 0,91$ 91%	De los 23 elementos claros de la interfaz, el participante N° 8 dejó de visualizar 2 elementos: - Botón: Inicio - Enlace: Vista previa
	9°	$X = A/B = 22/23 = 0,96$	De los 23 elementos claros de la interfaz, el participante N° 9 dejó de visualizar 1 elemento:

Métrica	Orden participantes	Medida	Observaciones
		96%	- Botón: Inicio
	10°	$X = A/B = 22/23 = 0,96$ 96%	De los 23 elementos claros de la interfaz, el participante N° 10 dejó de visualizar 1 elemento: - Botón: Inicio
Total		91%	El promedio de claridad de los elementos de la interfaz es del 91% en los casos en los que tales elementos se presentaron para informar o guiar al usuario. La claridad de los elementos de la interfaz definidos por la métrica coincide con el promedio de claridad de los elementos de la interfaz medido con los participantes con respecto a la métrica, confirmando así la tendencia de los usuarios a visualizar con claridad los elementos o no.

Tabla B.7b. Análisis de participantes de la métrica claridad en los elementos de la interfaz.

Grupo	Elementos	Medida	Observaciones
Elementos de la interfaz	Botones: 9 - Página de inicio: 4 - Página de perfil: 5	$X = A/B = 7/9 = 0,78$ 78%	Solo dos elementos de la interfaz no obedecen aspectos de usabilidad según la evaluación del estudio de caso (Véase Tabla 5.12).
	Enlaces: 6 - Página de inicio: 3 - Página de perfil: 3	$X = A/B = 5/6 = 0,83$ 83%	Solo un elemento de la interfaz no obedece aspectos de usabilidad pues no estaba incluido en la evaluación del estudio de caso.
	Imágenes con enlace: 8 - Página de inicio: 1 - Página de perfil: 7	$X = A/B = 6/8 = 0,75$ 75%	Dos elementos de la interfaz no obedecen aspectos de usabilidad pues deben hacerse de forma más intuitiva y especificada (Véase Tabla 5.12). Hay que resaltar que cuatro de los elementos no se encontraban incluidos en la evaluación del estudio de caso.

Grupo	Elementos	Medida	Observaciones
	Tarjetas de información: 5 - Página de inicio: 3 - Página de perfil: 2	$X = A/B = 5/5 = 1$ 100%	Todos estos elementos de la interfaz obedecen aspectos de usabilidad (Véase Tabla 5.12).
Formularios	Formulario: Acceso a la cuenta - Etiquetas: 2 - Cajas de texto: 2 - Botones: 1	$X = A/B = 5/5 = 1$ 100%	Todos los elementos del formulario obedecen aspectos de usabilidad (Véase Tabla 5.7).
	Formulario: Regístrate - Etiquetas: 3 - Cajas de texto: 3 - Botones: 1	$X = A/B = 7/7 = 1$ 100%	Todos los elementos del formulario obedecen aspectos de usabilidad (Véase Tabla 5.7).
	Formulario: Conocerte - Etiquetas: 7 - Cajas de texto: 3 - Listas de selección: 6 - Botones: 1 - Imagen con enlace: 1	$X = A/B = 18/18 = 1$ 100%	Todos los elementos del formulario obedecen aspectos de usabilidad (Véase Tabla 5.7).
Operaciones	Página de inicio - Registrarse - Acceder a la cuenta	$X = A/B = 2/2 = 1$ 100%	Todas las operaciones de la página de inicio obedecen aspectos de usabilidad según la evaluación del estudio de caso (Véase Tabla 5.8).
	Página de perfil - Cambiar avatar - Cambiar color - Cambiar configuraciones de cuenta (contraseña) - Vista previa de perfil - Conocerte - Calificar	$X = A/B = 5/6 = 0,83$ 83%	Solo una las operaciones de la página de perfil no obedece aspectos de usabilidad según la evaluación del estudio de caso (Véase Tabla 5.8).
Mensajes	Página de inicio - Usuario no registrado - Usuario registrado - Campo faltante en formulario de registro	$X = A/B = 5/5 = 1$ 100%	Todos los mensaje de la página de inicio obedecen aspectos de usabilidad dado que los que fueron mostrados fueron claros en su contenido (Véase Tabla 5.11). Algunos de estos no fueron necesarios de mostrar en la evaluación del estudio de caso.

Grupo	Elementos	Medida	Observaciones
	<ul style="list-style-type: none"> - Campo faltante en formulario de acceso - Usuario y/o contraseña incorrectas 		
	Página de perfil <ul style="list-style-type: none"> - Cambio de contraseña - Cambio de vista previa de perfil - Campo faltante en formulario de conocerte - Calificación de la recomendación - Videos no disponibles - Audios no disponibles - Textos no disponibles - Chat no disponible 	$X = A/B = 6/8 = 0,75$ 75%	Dos de los mensaje de la página de perfil no obedecen aspectos de usabilidad dado que algunos de los que fueron mostrados no fueron tan claros en su contenido (Véase Tabla 5.11). Algunos de estos no fueron necesarios de mostrar en la evaluación del estudio de caso.
Total		89%	El promedio de obediencia a las normas, estándares y convenciones de usabilidad de los elementos contemplados que conforman la aplicación implementada puede ser determinado como bueno, dado que el porcentaje de obediencia y cumplimiento supera en cada uno de los grupos contemplados el 75% de cumplimiento.

Tabla B.8. Análisis de la métrica cumplimiento de la usabilidad

El proceso completo consta de la consulta a la base de datos del usuario y la contraseña del usuario; seguido de la consulta del aprendizaje del usuario por parte del sistema, es decir las características de configuración de perfil del usuario. Por último, la carga de toda la información de usuario en la página de perfil. Este proceso dura cerca de 2 segundos en ejecutarse.

ANEXO C

En este anexo se exploran las funciones y código relacionado con el desarrollo de algoritmos y reglas usadas en esta tesis para la construcción del prototipo Cocare.

C.1. CBR

En este punto se describe el desarrollo del recomendador CBR que facilita el proceso de adicionar metadatos a los videos u contenidos multimedia que se agregan al sistema CoCare.

Su función es asignar un perfil completo a los videos, mediante el uso de casos cbr exitosos que han sido evaluados y valorados por expertos en salud. Apartir de su información se consigue completar información necesaria en nuevos contenidos, así el recomendador basado en conocimiento tendrá más datos a reaccionar en el momento de seleccionar la mejor recomendación para los usuarios.

CoCARE es un sistema de recomendaciones de contenido multimedia sobre actividad física. Estos contenidos han sido previamente seleccionados por expertos en salud. El sistema utiliza un algoritmo supervisado de árbol de decisiones que incorpora información de usuario y contexto para recomendar contenidos con base al estado actual del usuario. El conocimiento del usuario y su contexto explotado por CoCARE es información de localización proporcionada, por ejemplo, por GPS, sensores de ubicación en interiores (NFC), fecha (dada la estación), programa diario del usuario. Esta información se agrega al perfil de usuario y preferencias (ver **Tabla 9**), como los datos que el sistema aprende durante la interacción del usuario con el sistema (videos favoritos o dislike). El objetivo del sistema es ser fácilmente comprensible por cualquier persona y proporcionar recomendaciones personalizadas de una manera no invasiva. Los datos de contexto se obtienen en tiempo real, y las recomendaciones se mejoran dinmicamente a medida que el sistema aprende.

C1.2 CBR process

Nuestro sistema CBR descubre el perfil de usuario que mejor se adapte a la query. En la figura C1 se esquematiza el proceso CBR. En primer lugar, se seleccionan las categorías más similares para los nuevos videos a partir de su descripción **d**. Con similitud textual, el sistema compara las palabras de la descripción con la lista de categorías **V** del sistema (Ej. categoria= Bailar y keywords= prancing, tapping, dribbling, moving, braiding, waltz). Luego seleccionamos las 3 categorías con mayor peso **K1,K2,K3**.

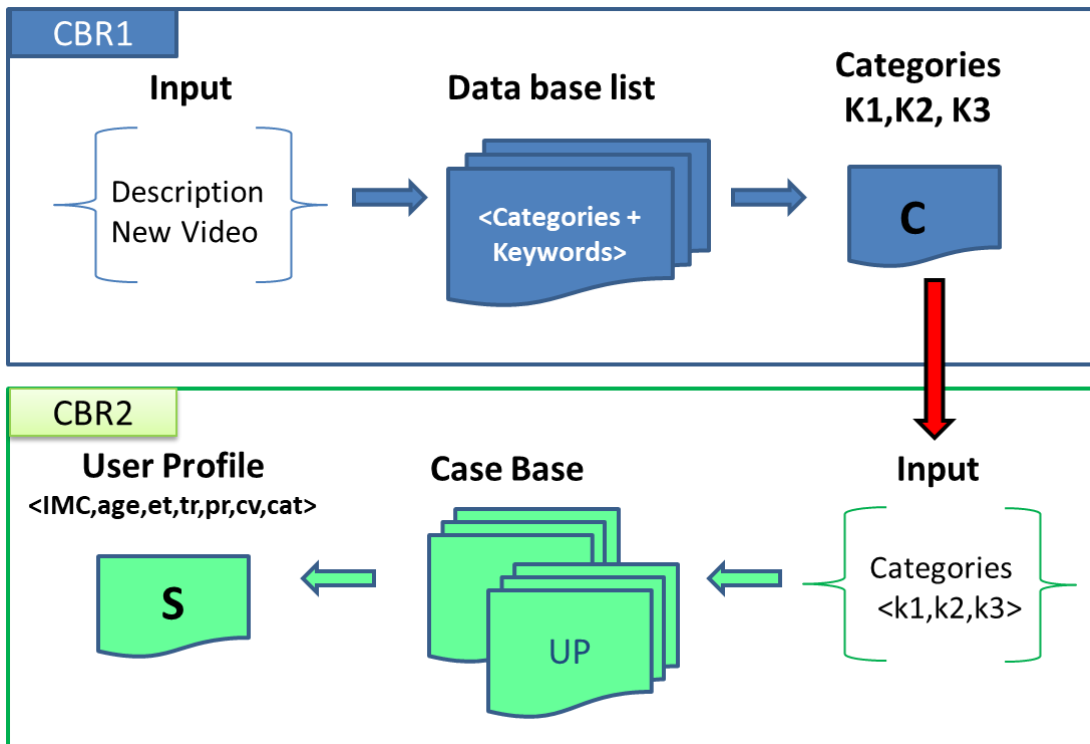


Figura C1. Proceso CBR

$$CB = \langle C_1, C_2, \dots, C_p \rangle \quad (1)$$

$$C = \langle \mathcal{V}, \mathcal{PU} \rangle \quad (2)$$

where

$$\mathcal{V} = \langle VC_1, VC_2, \dots, VC_m \rangle \quad (3)$$

$$\mathcal{VC} = \langle category, Keywords \rangle \quad (4)$$

$$UP = \langle UP_1, UP_2, \dots, UP_n \rangle \quad (5)$$

$$UP = \langle IMC, age, et, tr, pr, cv \rangle \quad (6)$$

S = Solution

El algoritmo CBR consulta en la base de casos CB los UP que contiene K1 o K2 o K3 y selecciona los perfiles de usuario adecuados ($UP_1 [UP_2; \dots; UP_n]$). Se procede a comparar uno a uno los valores de los atributos de los UP (ver tabla 1). Usando clasificacin de majoritng voting, seleccionamos el valor de cada atributo para el nuevo UP, encontrando la solucin S. Aplicamos cross validation al UP usando el metodo leave one out. Para que un caso sea aceptado y pase a ser parte de la base de casos, debe ser superior o igual a 0,75 y la categoría recuperada debe ser igual a la categoria consultada.

$$K_r = K_q \wedge Sim(PU_q, PU_r) \geq 0,75 \quad (7)$$

$$(8)$$

Recuperacion

En primer lugar seleccionamos las 3 categorías $\langle K1, K2, K3 \rangle$ con mayor peso a partir de la descripción del nuevo video 9. Si V esta contenida en Q se suma las veces que aparece, se ordenan por pesos y se seleccionan las K.

$$Q = \langle d1, d2, d3, \dots, dn \rangle \quad (9)$$

$$\text{If } V \subset Q \rightarrow W = \sum Q \quad (10)$$

$$\text{Sim}(Q,V) = \frac{V \cap Q}{Q} \quad (11)$$

$$(12)$$

Adaptacion

Para hallar el perfil de usuario UP adecuado nuestra query es K. Contamos con la base de casos CB que contiene los UP y al final se espera obtener la mejor solución S. Un UP esta conformado por varios atributos asi: indcardiavasculas indice de masa corporal (BMI), life cycle (age), ethnicity(et),Trauma(tr),preference(pr),cardiovascular disease(cv).

$$K = \langle K1, K2, K3 \rangle \quad (13)$$

$$UP = \langle BMI, age, et, tr, pr, cv \rangle \quad (14)$$

$$(15)$$

Implementamos un algoritmo CBR usando el clasificador de majoriting voting (ec 16). Primero se seleccionan todos los Casos C contenidos en CB que contengan la categoria similar a K (ec 17). Luego cada atributo de UPK se compara uno a uno, seleccionando el de mayor peso (ec 18). Para obtener la solución S usamos majoriting voting para seleccionar solo una categoria K (ec 19). Asi obtenemos el perfil de usuario y la categoria mas adecuada para el nuevo video.

$$Q_c \subset UP. \quad (16)$$

$$UP_K = (PU_{k1} \cup PU_{k2}, \dots, \cup PU_{km}) \quad (17)$$

$$\text{Majoriting Voting}(UP_K) \quad (18)$$

$$\text{Majoriting Voting}(K1 \cup K2 \cup K3) \quad (19)$$

$$S = \langle UP_K, K \rangle \quad (20)$$

Cross validation

Usando el Metodo de sustitucion leave one out, nosotros hicimos una sustitucion basada en casos. En nuestra CB hemos adicionado el caso que recuperamos UPk y a su vez hemos dejado por fuera un caso antiguo C.

Para nuestra validacion la categoria del caso C ser nuestra query Q y vamos a recuperar el perfil más adecuado.

$$C = \langle UP_i, V \rangle \quad (21)$$

$$Q = V \quad (22)$$

$$UP_r = \text{recuperado} \quad (23)$$

$$\text{Sim}(PU_q, PU_r) = \frac{UP_i \cap UP_r}{N} \quad (24)$$

Where

$$N = \text{Attributes} \quad (25)$$

Procedemos a medir y verificar si su valor supera 0; 75. Comparamos cada uno de los atributos de UPr.

C.2. Recomendador

En este Anexo se deja conocer la estructura y unos ejemplos de las funciones que se usaron en sistema de recomendaciones CoCARE.

Estructura del Proyecto

Como se puede observar en la figura C2.1, la estructura del sistema de recomendaciones del proptotipo de esta tesis se basa en los conceptos propuestos en la ontologia OntoCocare descrita en la Sesión 2.1.8 y el del data set de usuarios, contexto y videos, además de los metadatos tomados por el cbr y la similaridad que se describe en las sesiones Métricas de similaridad3.1.1y 3.1.5 de este documento.


```
Collection<RetrieveResult> evals = null;
modeUsed = "";
switch (mode) {
    case CFEuclidean:
        config.setDescriptionSimFunction(cfEuclideanSim);
        evals = NNScoringMethod.evaluateSimilarity(cfCaseBase.getCases(), query, config);
        calculateCFRating(evals, query);
        break;
    case CFPearson:
        config.setDescriptionSimFunction(cfPearsonSim);
        evals = NNScoringMethod.evaluateSimilarity(cfCaseBase.getCases(), query, config);
        calculateCFRating(evals, query);
        break;
    case CBItems:
        config.setDescriptionSimFunction(cbItemSim);
        evals = NNScoringMethod.evaluateSimilarity(cbCaseBase.getCases(), query, config);
        calculateCBRating(evals, query);
        break;
    case ICCBR17:
        if (RatingDAOImpl.getInstance().getRatingsByMovie(idItemSearched).size() > minRating) {
            config.setDescriptionSimFunction(cfPearsonSim);
            evals = NNScoringMethod.evaluateSimilarity(cfCaseBase.getCases(), query, config);
            calculateCFRating(evals, query);
            modeUsed = "CFPearson";
        } else {
            config.setDescriptionSimFunction(cbItemSim);
            evals = NNScoringMethod.evaluateSimilarity(cbCaseBase.getCases(), query, config);
            calculateCBRating(evals, query);
            modeUsed = "CBItem";
        }
        break;
}
```

Figura C 2.2. Recomendador principal

Estas son las funciones de recomendación que se usaron en Cocare, a continuación se observan las funciones implementadas de distancia euclideana y coeficiente de Pearson en las siguientes figuras.

```
public class CFEuclideanSimilarity implements GlobalSimilarityFunction {

    @Override
    synchronized public double compute(CaseComponent componentOfCase, CaseComponent componentOfQuery, CBRCase

        UserDescription queryDesc = (UserDescription) _query.getDescription();
        UserDescription caseDesc = (UserDescription) _case.getDescription();

        // Search equal items
        List<RatingBean> queryRatings = queryDesc.getRatings().stream()
            .filter(r -> caseDesc.containsMovie(r.getMovieId()))
            .collect(Collectors.toList());
        queryRatings.sort((RatingBean r1, RatingBean r2)->r1.getMovieId()-r2.getMovieId());

        List<RatingBean> caseRatings = caseDesc.getRatings().stream()
            .filter(r -> queryDesc.containsMovie(r.getMovieId()))
            .collect(Collectors.toList());
        caseRatings.sort((RatingBean r1, RatingBean r2)->r1.getMovieId()-r2.getMovieId());

        if(!queryRatings.isEmpty() && !caseRatings.isEmpty()) {
            double aux = 0.0;

            for(int i=0; i<queryRatings.size(); i++)
                aux += Math.pow(((double) queryRatings.get(i).getRating() - ((double) caseRatings.get(i).getR

            return 1.0/ (1 + Math.sqrt(aux));
        } else
            return 0.0;
    }

    private RatingBean getRating(List<RatingBean> ratings, int movieId) {
        return ratings.stream()
            .filter(r -> r.getMovieId() == movieId)
            .findFirst().get();
    }
}
```

Figura C 2.3. Función principal

Euclidean

En la figura C2.4. se desgloza la función de distancia euclideana.

```
Collection<RetrieveResult> evals = null;
modeUsed = "";
switch (mode) {
    case CFEuclidean:
        config.setDescriptionSimFunction(cfEuclideanSim);
        evals = NNScoringMethod.evaluateSimilarity(cfCaseBase.getCases(), query, config);
        calculateCFRating(evals, query);
        break;
    case CFPearson:
        config.setDescriptionSimFunction(cfPearsonSim);
        evals = NNScoringMethod.evaluateSimilarity(cfCaseBase.getCases(), query, config);
        calculateCFRating(evals, query);
        break;
    case CBItems:
        config.setDescriptionSimFunction(cbItemSim);
        evals = NNScoringMethod.evaluateSimilarity(cbCaseBase.getCases(), query, config);
        calculateCBRating(evals, query);
        break;
    case ICCBR17:
        if(RatingDAOImpl.getInstance().getRatingsByMovie(idItemSearched).size() > minRating) {
            config.setDescriptionSimFunction(cfPearsonSim);
            evals = NNScoringMethod.evaluateSimilarity(cfCaseBase.getCases(), query, config);
            calculateCFRating(evals, query);
            modeUsed = "CFPearson";
        } else {
            config.setDescriptionSimFunction(cbItemSim);
            evals = NNScoringMethod.evaluateSimilarity(cbCaseBase.getCases(), query, config);
            calculateCBRating(evals, query);
            modeUsed = "CBItem";
        }
        break;
}
```

Figura C2.4. Euclidean

Pearson

Además de la similaridad de distancia euclideana se probaron otras como coeficiente de Pearson, coseno, y otras que se detallan en las sesiones anteriores.

```
@Override
public double compute(CaseComponent componentOfCase, CaseComponent componentOfQuery, CBRCase _case, CBRQuery _query, NNC

    UserDescription caseDesc = (UserDescription) _case.getDescription();
    UserDescription queryDesc = (UserDescription) _query.getDescription();

    List<RatingBean> ratingsCase = caseDesc.getRatings().stream()
        .filter(r -> queryDesc.containsMovie(r.getMovieId()))
        .collect(Collectors.toList());
    ratingsCase.sort((RatingBean r1, RatingBean r2)->r1.getMovieId()-r2.getMovieId());

    List<RatingBean> ratingQuery = queryDesc.getRatings().stream()
        .filter(r -> caseDesc.containsMovie(r.getMovieId()))
        .collect(Collectors.toList());
    ratingQuery.sort((RatingBean r1, RatingBean r2)->r1.getMovieId()-r2.getMovieId());

    if(!ratingsCase.isEmpty() && !ratingQuery.isEmpty()) {
        double avrCase = ratingsCase.stream()
            .map(RatingBean::getRating)
            .mapToDouble(Double::new)
            .average().getAsDouble();

        double avrQuery = ratingQuery.stream()
            .map(RatingBean::getRating)
            .mapToDouble(Double::new)
            .average().getAsDouble();

        double aux1 = 0.0;
        double aux2 = 0.0;
        double aux3 = 0.0;

        for (int i = 0; i < ratingQuery.size(); i++) {
            aux1 += (((double) ratingsCase.get(i).getRating() - avrCase) *
                ((double) ratingQuery.get(i).getRating() - avrQuery));
            aux2 += Math.pow(((double) ratingsCase.get(i).getRating() - avrCase, 2);
            aux3 += Math.pow(((double) ratingQuery.get(i).getRating() - avrQuery, 2);
        }
    }
}
```

Figura C 2.5. Pearson