



Universidad del Bío-Bío
Facultad de Ciencias Empresariales
Departamento de Sistemas de Información
Magíster en Ciencias de la Computación

Incorporando Indicador de Confianza sobre la Calidad de Información Contextual en Sistemas de Recomendación Conscientes del Contexto

Tesis presentada por Joel Torres Carrasco
para optar al Grado de Magíster en Ciencias de la Computación
Dirigida por el profesor Dr. Pedro G. Campos

Concepción, Chile – 2018

Agradecimientos

En primer lugar, agradezco a Dios por su permanente sustento y fortaleza, especialmente, en los momentos más difíciles que he pasado.

Así también, agradezco al profesor Dr. Pedro G. Campos Soto por guiar este trabajo, quien, a través de su experiencia y conocimiento en el área, la enseñanza constante, sobre todo, su paciencia, comprensión y dedicación, se ha convertido en un mentor durante la investigación. Además, a todos los demás académicos quienes me ayudaron a aclarar temas relacionados, o que simplemente compartimos una conversación.

Agradezco a mis compañeros y amigos del programa de Magíster en Ciencias de la Computación, en especial, a Cristian, Jorge, Luís, Raúl y Juan José, con quienes compartí días y noches de estudio, de investigación, de conversaciones misceláneas, de tristezas y de alegrías. De igual forma, agradezco a todos aquellos que han estado pendientes de este proceso, que han preguntado, dado ánimo y buenos deseos.

Finalmente, no podría haber soportado todo este proceso sin la ayuda de mis padres y mis hermanos, mis tíos y primos, quienes me han apoyado en mis decisiones. Igualmente, agradezco a Keyti por su amor y ternura, haciendo que este proceso sea más ligero. Es por todo este amor, que este trabajo está dedicado a ellos, a mis seres queridos, ya que mi vida ha sido bendecida por cada uno de ellos.

Este trabajo de tesis ha sido financiado en parte por el proyecto DIUBB 151115 4/R "iCARS: Ampliando la investigación en Sistemas de Recomendación Consciente del Contexto más allá de las valoraciones explícitas".

Resumen

Los sistemas de recomendación (RS) entregan mejores sugerencias a sus usuarios cuando se procesa mejor información. Actualmente, existen RS que incorporan información de contexto en las sugerencias. Contexto es todo aquel dato, excepto usuario e ítem, que condicione la elección del usuario sobre un ítem.

Una interesante fuente de información contextual son los comentarios realizados por los usuarios al calificar un ítem. Usando métodos estándar del área de Extracción de Información para aumentar la información disponible, es posible extraer esta información de manera automática, aunque con diversos grados de calidad. Por esto resulta interesante considerar la confianza que se puede tener en la información obtenida.

En este trabajo, se presenta una estrategia de Extracción de Información basada en una taxonomía de información contextual que permite extraer información de contexto desde fuentes textuales (*reviews*) de manera automática. Se ha considerado el análisis de literatura referente a modelado de contexto en sistemas ubicuos, pervasivos, y de recomendación, y se ha generado una taxonomía que describe conceptos de información de contexto. En conjunto con ello, se ha desarrollado un algoritmo para pre-filtrar la información obtenida, en base a un indicador de confianza en la información detectada.

Finalmente, se realiza un detallado análisis del impacto del uso de la información de contexto obtenida en base a la taxonomía desarrollada. Además, se considera el efecto de diferentes estrategias para medir la confianza en la información, en los resultados del proceso de recomendación consciente del contexto.

Palabras clave – Sistemas de Recomendación, Taxonomías de Contexto, Algoritmos de Recomendación, Extracción de Información.

Abstract

Recommender Systems (RS) produce better suggestions to users when better information is processed. Currently, there are RS that use context information for the generation of suggestions. Context is the information, except user and item, which condition the user election about an item.

An interesting source of contextual information corresponds to reviews made by users about an item. It is possible to retrieve this information in an automatic fashion by using standard methods from Information Extraction to increase the available information, although with diverse quality. Hence, it is interesting to consider how reliable is the obtained information—i.e. the level of trust in the information.

In this work, a taxonomy-based information extraction strategy is presented, that let extract context information from text sources (*reviews*) in an automatic way. A review of literature about context modeling in ubiquitous, pervasive, and recommender systems is considered, and a taxonomy that describe context information concepts has been built. In addition, an algorithm to pre-filtering obtained information has been developed, based on an indicator of trust on detected information.

Finally, a detailed analysis of the use of obtained context information based on the developed taxonomy is made. In addition, the effect of different strategies to measure the trust on context data in the results of the context-aware recommendation process is considered.

Keywords – Recommender Systems, Context Taxonomy, Recommendation Algorithms, Information Retrieval

ÍNDICE DE CONTENIDOS

Capítulo 1	Introducción.....	11
1.1.	Problemática de la investigación	12
1.2.	Hipótesis	13
1.3.	Objetivos	13
	Objetivo General	13
	Objetivos Específicos	13
1.4.	Contribuciones de este trabajo.....	14
1.5.	Distribución de Capítulos.....	14
Capítulo 2	Marco Conceptual.....	15
2.1.	Sistemas de Recomendación.....	15
2.1.1.	Técnicas de Sistemas de Recomendación.....	16
2.1.2.	Sistemas de Recomendación Conscientes del Contexto (CARS).....	19
2.1.3.	CARSKit: Librería Especializada en CARS.....	24
2.1.4.	Obtención de información de contexto.....	29
2.1.5.	Confianza (Trust) en Sistemas de Recomendación.....	31
2.1.6.	Evaluación de Sistemas de Recomendación.....	32
Capítulo 3	Modelado de información de contexto.....	36
3.1.	Modelos de información contextual.....	37
3.2.	Análisis de ontologías de información de contexto.....	41
3.3.	Dimensiones de información utilizadas en sistemas conscientes del contexto.....	42
Capítulo 4	Taxonomía para Anotación de Información Contextual.....	50
4.1.	Estructura de la Taxonomía	51
4.2.	Información incluida en la Taxonomía	54
4.2.1.	Obtención de instancias en DBpedia	55
4.2.2.	Obtención de sinónimos en Wordnet.....	55
4.2.3.	Obtención de derivaciones en Wordnet.....	55
4.2.4.	Revisión manual	56
4.3.	Identificación y anotación de información de contexto.....	56
4.3.1.	Selección de palabras candidatas	57

4.3.2.	Matching de palabras candidatas y valores contextuales.....	58
Capítulo 5	Pre-filtrado basado en Confianza.....	59
5.1.	Indicador de Confianza	59
5.1.1.	Levenshtein.....	60
5.1.2.	Damerau-Levenshtein.....	60
5.1.3.	Jaro-Winkler.....	61
5.2.	Indicador de Confianza basado en Algoritmos de Distancia de Edición.....	62
5.3.	Algoritmo de Pre-filtrado basado en Confianza	63
Capítulo 6	Experimentación de Algoritmos.....	66
6.1.	Planificación de la Experimentación	66
6.1.1.	Descripción de Datasets.....	68
6.1.2.	Metodología de experimentación	70
Capítulo 7	Análisis de Resultados y Discusión	73
7.1.	Análisis del impacto de la taxonomía de contexto.....	74
7.1.1.	Análisis sobre el uso de categorías de contexto en la predicción de ratings..	74
7.1.2.	Análisis sobre el uso de categorías de contexto en el ranking de ítems recomendados	77
7.2.	Análisis de Comportamiento usando diferentes indicadores de Confianza	82
7.2.1.	Análisis sobre algoritmo de distancia de edición.....	85
7.2.2.	Análisis sobre nivel de confianza	85
7.3.	Discusión	86
Capítulo 8	Conclusiones y Trabajos Futuros.....	88
8.1.	Contribuciones de la Investigación.....	89
8.2.	Trabajo Futuro	90
Referencias	92
Anexos	103
Anexo 1:	Resultados extendidos de experimentación.....	103

ÍNDICE DE FIGURAS

Figura 1: Ejemplo matriz kNN en el dominio de recomendación de películas (Antunes, Cordeiro, & Gomes, 2012).....	17
Figura 2: Ejemplo de estructura jerárquica de información de contexto dimensión Tiempo...	20
Figura 3: Información contextual en modelo multidimensional basado en OLAP (Adomavicius et al., 2005).....	20
Figura 4: Componentes generales del proceso de recomendación tradicional (2D) (Adomavicius et al., 2005).....	21
Figura 5: Paradigmas para la incorporación de información de contexto en RS (Adomavicius et al., 2005). (a) Pre-filtrado contextual, (b) Post-filtrado contextual, (c) Modelado contextual.....	21
Figura 6: Efecto de la aproximación ItemSplitting en la matriz de ratings.....	25
Figura 7: Representación modelo de contexto	39
Figura 8: Estructura Jerárquica de dimensiones de contexto en GUMO.....	40
Figura 9: Estructura Jerárquica de Dominios OpenCyc.....	41
Figura 10: Estructura Jerárquica nueva Taxonomía de Información de Contexto	52
Figura 11: Ejemplo de Nivel de Similitud entre término de Review y término de Taxonomía (a) Ejemplo de Review en Tripadvisor, (b) Rama Spouses - Extracto de Taxonomía de Contexto.....	62
Figura 12: Representación de Algoritmo de Pre-filtrado basado en Indicador de Confianza ..	63
Figura 13: Proceso de Experimentación.....	67

ÍNDICE DE TABLAS

Tabla 1: Técnicas de Modelado de Contexto en la literatura revisada.....	38
Tabla 2: Dimensiones de contexto en estudios revisados	44
Tabla 3: Resultados de algoritmos de distancia de edición	63
Tabla 4: Números de Usuarios, Ítems y Reviews por cada Dataset usado en la Experimentación	68
Tabla 5: Categorías de contexto usadas en experimentación	70
Tabla 6: Resumen de Algoritmos de Recomendación usados en la Experimentación	71
Tabla 7: Métricas de evaluación de algoritmos de recomendación usadas en experimentación	72
Tabla 8: Métricas de evaluación de algoritmos Baseline sobre datasets Yelp Beauty Spas y Yelp Hotels	73
Tabla 9: Métricas de Rating sobre dataset Yelp Beauty Spas	75
Tabla 10: Métricas de Rating sobre dataset Yelp Hotels	76
Tabla 11: Métricas de Ranking sobre dataset Yelp Beauty Spas	79
Tabla 12: Métricas de Ranking sobre dataset Yelp Hotels.....	80
Tabla 13: Métricas sobre dataset Yelp Beauty Spas en distintos indicadores de confianza	83
Tabla 14: Métricas sobre dataset Yelp hotels en distintos indicadores de confianza	84
Tabla 15: Resultados extendidos de métricas de evaluación de algoritmos Baseline sobre datasets Yelp Beauty Spas y Yelp Hotels.....	103
Tabla 16: Métricas de evaluación extendida sobre dataset Yelp Beauty Spas.....	108
Tabla 17: Métricas de evaluación extendida sobre dataset Yelp Hotels.....	113
Tabla 18: Métricas de evaluación extendida sobre dataset Yelp Beauty Spas – CAMF_C..	116
Tabla 19: Métricas de evaluación extendida sobre dataset Yelp Beauty Spas – UserSplitting- ItemKNN	118
Tabla 20: Métricas de evaluación extendida sobre dataset Yelp Hotels – CAMF_C.....	120
Tabla 21: Métricas de evaluación extendida sobre dataset Yelp Hotels – UserSplitting- ItemKNN	122

Capítulo 1

Introducción

Los Sistemas de Recomendación (RS, de sus siglas en inglés *Recommender Systems*) son herramientas de software y técnicas que proveen recomendaciones de ítems que sean del interés de los usuarios (Kantor, Ricci, & Rokach, 2009).

El acelerado incremento de información disponible, que se ha acentuado con la aparición de Internet, puede hacer difícil la elección de un ítem para el usuario (Bobadilla, Ortega, Hernando, & Gutiérrez, 2013; Kantor et al., 2009; Leskovec, 2015). Por esta razón, el desarrollo de RS también ha aumentado sostenidamente, debido al creciente número de ítems disponibles, mayor diversificación en la venta de ítems, fidelidad del usuario, y proveer de ítems más deseados (Amatriain, 2016; Gomez-Uribe & Hunt, 2015; Leskovec, 2015).

De esta manera, los RS juegan un rol importante en el desarrollo de compañías y organizaciones con grandes catálogos digitales de productos o servicios, tales como Amazon.com¹, Tripadvisor², Last.fm³, Netflix⁴ (Amatriain, 2016; Gomez-Uribe & Hunt, 2015), entre otras.

Además, algunas investigaciones actuales se han enfocado en obtener más información para generar recomendaciones más precisas (Adomavicius & Tuzhilin, 2005b; Riedl & Jameson, 2007; Zoeter, 2015). Una de las aproximaciones que ha generado gran interés son los sistemas de recomendación conscientes del contexto (Adomavicius, Mobasher, Ricci, & Tuzhilin, 2011), que generan recomendaciones personalizadas más precisas a través de información adicional sobre la situación (o contexto) en que los usuarios manifiestan sus preferencias. En general, se considera como contexto a la situación o circunstancias en que un usuario interactúa con un ítem y, por tanto, pueden influir en el nivel de agrado o preferencia que tiene por dicho ítem. Por ejemplo, la localización del usuario (en su hogar, en su oficina, en el cine, etc.), el momento

¹ Compañía de Venta Online (e-commerce), disponible en: <https://www.amazon.com>

² Compañía de recomendación para viajes, disponible en: <https://www.tripadvisor.com>

³ Catálogo Musical Online, disponible en: <https://www.last.fm>

⁴ Compañía de transmisión de contenido audiovisual vía streaming, disponible en: <https://www.netflix.com>

de tiempo (momento del día, día de la semana, estación del año, etc.), en compañía de quién se encuentra (sólo, con amigos, con su pareja, con niños, con mascotas, etc.), su estado de ánimo (triste, alegre, etc.), o el clima (lluvioso, soleado, etc.), pueden influir de diferentes maneras, dependiendo del dominio de recomendación.

1.1. Problemática de la investigación

A pesar del interés que han generado los sistemas de recomendación conscientes del contexto, existe una escasez de información de contexto asociada a las preferencias de los usuarios, que impide que las aproximaciones conscientes del contexto puedan mejorar los resultados del proceso de recomendación.

Este problema de escasez radica en la dificultad para adquirir información de contexto, ya que se obtiene, muchas veces, de manera explícita, es decir, preguntando directamente al usuario, lo cual puede no ser de su agrado, por ejemplo, por preocupaciones de privacidad, generando rechazo a entregar dicha información. Por otro lado, es posible obtener este tipo de información de manera automática a partir de sensores, como por ejemplo, la localización mediante dispositivos GPS, hoy incorporados en *smartphones*, o el momento de tiempo, a partir de las marcas de tiempo del sistema utilizado. Sin embargo, en el caso de otras dimensiones contextuales, tales como compañía, estado de ánimo o clima, en general no es factible capturar información mediante sensores para propósitos de recomendación.

Una aproximación reciente, plantea usar fuentes textuales tales como *reviews* – comentarios que los usuarios emiten de manera libre sobre su experiencia con ítems– para, mediante un proceso automático de Extracción de Información, obtener información contextual (Campos, Rodríguez-Artigot, & Cantador, 2017). Sin embargo, al ser la Extracción de Información de fuentes textuales hecha de forma automática, la calidad de los datos de contexto obtenidos puede variar considerablemente. Por consiguiente, la calidad de las recomendaciones puede verse afectada por la calidad de la información usada en el proceso de recomendación. Es así que en esta tesis se propone mejorar la capacidad de incorporar información contextual extraída automáticamente desde fuentes textuales externas (*reviews*), utilizando para ello una taxonomía de información de contexto cuidadosamente elaborada, e incorporando un indicador de confianza en la información obtenida, de manera que esta información pueda ser utilizada de manera efectiva en algoritmos de recomendación consciente del contexto. Cabe señalar que algunos trabajos previos han propuesto taxonomías para capturar información de contexto en dominios específicos. Sin embargo, dichas taxonomías no son aplicables a dominios diferentes a aquel para el cual fueron diseñadas. Por el contrario, en este trabajo se plantea generar una taxonomía genérica, que sea aplicable a diferentes dominios de recomendación, facilitando así

la obtención de información necesaria para el uso en algoritmos de recomendación conscientes del contexto.

1.2. Hipótesis

Las hipótesis de esta tesis son:

H1. Es posible obtener información contextual desde fuentes de texto (*reviews*), usando una taxonomía específica para este propósito y métodos usados en Extracción de Información.

H2. Es posible obtener recomendaciones contextualizadas más precisas usando un algoritmo que considere un indicador de confianza sobre información de contexto obtenida automáticamente.

1.3. Objetivos

Objetivo General

Desarrollar una aproximación de recomendación consciente del contexto que tome en cuenta el nivel de confianza de información de contexto extraída automáticamente desde fuentes textuales (*reviews*) usando un proceso de extracción de información basado en Taxonomías.

Objetivos Específicos

Los objetivos específicos de esta tesis son:

1. Obtener una taxonomía de información contextual, por ejemplo, aspectos personales como emociones o aspectos de entorno, como quiénes acompañan al usuario, enfocada en dimensiones de contexto existentes en *reviews* que facilite la identificación automática de información contextual existente en ellas.
2. Desarrollar una aproximación para incorporar en algoritmos de generación de recomendaciones conscientes del contexto, el nivel de confianza en la información contextual obtenidas automáticamente desde fuentes textuales.
3. Proveer un análisis experimental sobre esta aproximación, evaluando el comportamiento (rendimiento) contrastado con otras aproximaciones.

1.4. Contribuciones de este trabajo

Como principales contribuciones de esta tesis, se destaca 1) la revisión de literatura referente a modelado contextual, que permite tener una visión general de cómo se modelan las diferentes dimensiones de contexto consideradas en diferentes sistemas; 2) la creación de una estructura jerárquica de categorías de contexto en las dimensiones de aspectos personales, aspectos sociales y aspectos de entorno, en base al estudio de la literatura del área; y 3) la definición de un algoritmo de pre-filtrado de información basado en un indicador de confianza en información de contexto extraída de forma automática. Todo lo anterior, permite obtener mejores recomendaciones mediante sistemas de recomendación conscientes del contexto, tomando como insumo comentarios textuales de usuarios para obtener la información de contexto. Para verificar las mejoras, y las hipótesis planteadas, se han realizado una serie de experimentos sobre datos reales de *reviews* de usuarios.

1.5. Distribución de Capítulos

Este informe de tesis se organiza como sigue. El presente capítulo introduce la problemática abordada y detalla las hipótesis y objetivos de este trabajo. En el Capítulo 2, se revisa el marco conceptual involucrado. En el Capítulo 3, se presenta una revisión de literatura referente a modelado de contexto. En el Capítulo 4, se describe la construcción de la taxonomía de información contexto propuesta y el proceso automático de obtención de información de contexto. En el Capítulo 5, se presenta un algoritmo de pre-filtrado basado en confianza en la información contextual obtenida. En el Capítulo 6, se describe el proceso de experimentación. En el Capítulo 7, se presenta un análisis de los resultados de la experimentación y una discusión sobre ellos. Finalmente, en el Capítulo 8, se entregan las conclusiones de este trabajo.

Capítulo 2

Marco Conceptual

En este capítulo se presenta el marco conceptual utilizado en el desarrollo de este trabajo. En primer lugar, se describe el área de estudio de los sistemas de recomendación, para luego presentar el procesamiento de lenguaje natural y técnicas de extracción de información aplicada al área de estudio, y finalmente, se mencionan las métricas de evaluación utilizadas para medir distintos criterios sobre RS.

2.1. Sistemas de Recomendación

Los Sistemas de Recomendación están dirigidos hacia aquellos individuos que no poseen la suficiente experiencia personal o competencia para evaluar el potencialmente abrumante número de ítems alternativos que un sistema web puede ofrecer (Abel, 2015; Amatriain, 2016; Resnick & Varian, 1997). Siendo las recomendaciones personalizadas las más comunes, haciendo que los usuarios se beneficien de estas sugerencias adaptadas a sus gustos respectivos. También existen las recomendaciones no personalizadas, por ejemplo, listas de productos "Best Seller".

El desarrollo de RS fue impulsado por la explosiva aparición de sitios web de *e-commerce* (Amatriain, 2016), y con ellos la necesidad de proveer recomendaciones para todo el rango de alternativas de ítems disponibles. Es decir, esta gran diversidad de alternativas dificulta la toma de decisiones por parte de los usuarios.

Es así, que los RS han proveído un medio significativo para afrontar el problema de la sobrecarga de información (Ricci, Rokach, & Shapira, 2015). Por lo tanto, las organizaciones y los usuarios se benefician de los ingresos por las recomendaciones, y de ítems recomendados más relevantes para los usuarios, respectivamente.

Los RS emergieron como un área de investigación independiente a mitad de la década de los 90's (Balabanović & Shoham, 1997; Goldberg, Nichols, Oki, & Terry, 1992; Resnick, Iacovou, Suchak, Bergstrom, & Riedl, 1994; Shardanand & Maes, 1995). Actualmente, esta área

ha seguido desarrollándose por el constante interés por parte de las organizaciones que recurren a estos sistemas.

2.1.1. Técnicas de Sistemas de Recomendación

Las técnicas para RS son caracterizadas por algoritmos de filtrado que se basan en la información del ítem, el perfil de usuario, y las preferencias expresadas por los usuarios sobre los diversos ítems. Según estos criterios, se pueden clasificar estas técnicas de la siguiente manera: algoritmos de filtrado basado en el contenido, algoritmos de filtrado colaborativo, y algoritmos de filtrado híbrido. A continuación, se revisarán las técnicas de filtrado más relevantes en la literatura:

2.1.1.1. Filtrado basado en Contenido (Content-Based Filtering)

El filtrado basado en contenido genera recomendaciones en base a las elecciones de los usuarios realizadas en el pasado, es decir, recomienda ítems que son similares a otros ítems que al usuario le gustaron en el pasado (Bobadilla et al., 2013; Pazzani & Billsus, 2007). De esta manera, esta técnica usa el contenido de los objetos (atributos) para comparar los ítems, y generar recomendaciones.

La Similitud de ítems es calculada a partir de las características asociadas a los ítems comparados. Por ejemplo, si un usuario ha calificado positivamente un ítem, como una película, que tiene una característica específica, como el género de películas "terror", entonces el sistema puede aprender a recomendar otros ítems que tengan también esa característica, es decir, que sugiera películas del género "terror" (Ricci, Rokach, & Shapira, 2015).

Las técnicas clásicas de recomendación basadas en contenido proponen comparar los atributos del perfil del usuario (Ricci, Rokach, & Shapira, 2015), un conjunto de características (atributos) extraídas desde la descripción de los ítems que le han gustado al usuario, contra los atributos de los ítems. Generalmente, los atributos son palabras clave que son extraídas desde la descripción de los ítems.

Existen nuevas investigaciones que proponen técnicas de indexado semántico para representar ítems y usuarios a través de conceptos en lugar de palabras clave. Además, se tiende a la integración con fuentes de conocimiento externas, tales como: ontologías (Middleton, Shadbolt, & De Roure, 2004; Salles & Willrich, 2015), conocimiento enciclopédico (Leskovec, 2015; Mihalcea & Csomai, 2007) y datos enlazados o *Linked Data* (Ko, Son, & Ko, 2015; Meymandpour & Davis, 2012).

2.1.1.2. Filtrado Colaborativo (Collaborative Filtering)

El filtrado colaborativo (FC) usa ratings que ha entregado el usuario, lo que representa la opinión del usuario sobre cierto ítem mediante el uso de una escala específica (Balabanović & Shoham, 1997), a un conjunto de elementos (ítems), en conjunto con ratings entregados por otros usuarios. De esta manera, cuando existe suficiente información almacenada en el sistema, es posible usarla para generar recomendaciones basadas en usuarios que tienen gustos similares (Goldberg et al., 1992). Además de la información de rating, es posible adquirir información implícitamente, por ejemplo, cantidad de veces que se accedió al ítem.

El algoritmo más ampliamente usado para FC es el de k vecinos más cercanos (kNN, por su sigla en inglés *k nearest neighbors*), debido a su simplicidad, eficiencia y habilidad para producir recomendaciones precisas y personalizadas. Este algoritmo considera a aquel usuario que se debe entregar recomendaciones como *usuario activo* a , luego trabaja con todos los usuarios similares a este usuario a (ver figura 1). Una vez definido este grupo, se ocupan los ratings que han realizado para predecir los ratings de aquellos ítems que el usuario a aún no ha visto. Finalmente, se escogen los ítems que reciben predicción de ratings más altos para mostrarlos al usuario a como ítems recomendados.

	<i>Batman Begins</i>	<i>Alice in Wonderland</i>	<i>Dumb and Dumber</i>	<i>Equilibrium</i>
User A	4	?	3	5
User B	?	5	4	?
User C	5	4	2	?
User D	2	4	?	3
User E	3	4	5	?

Figura 1: Ejemplo matriz kNN en el dominio de recomendación de películas (Antunes, Cordeiro, & Gomes, 2012)

Por ejemplo, en la Figura 1, el usuario B es el usuario activo, y se requiere predecir el rating para el ítem "Batman Begins"; en este caso, el grupo de usuarios similares lo conforma el usuario E , ya que sus ratings son muy similares al usuario B y, por lo tanto, se utiliza su rating para la predicción.

El algoritmo kNN puede utilizar la fórmula de Resnick (Resnick et al., 1994) para generar predicciones de ratings $\hat{r}_{a,i}$ para el usuario a sobre el ítem i . A continuación, se presenta la fórmula de predicción:

$$\hat{r}_{a,i} = \bar{r}_a + \frac{\sum_{u \in N} (r_{u,i} - \bar{r}_u) \times \text{sim}(a, u)}{\sum_{u \in N} \text{sim}(a, u)} \quad (1)$$

En la ecuación (1), la expresión \bar{r}_a representa el promedio de todos los ratings dados por el usuario a , mientras que $r_{u,i}$ es el rating dado por el usuario u sobre el ítem i , y \bar{r}_u representa

el promedio de ratings del usuario u , donde $u \in N$. Este conjunto N contiene a los k usuarios que son más similares al usuario a . Para construir este conjunto N , generalmente se computa el promedio del valor de similitud entre el usuario a y cada usuario u del conjunto de usuarios, luego, se ordenan de mayor a menor similitud y se eligen los primeros k usuarios del conjunto.

Para determinar la similitud entre usuarios $sim(a, u)$ se suele utilizar el Coeficiente de Correlación de Pearson (Resnick et al., 1994):

$$sim(a, u) = \frac{\sum_{i \in I_{au}} (r_{a,i} - \bar{r}_a)(r_{u,i} - \bar{r}_u)}{\sqrt{\sum_{i \in I_{au}} (r_{a,i} - \bar{r}_a)^2 \sum_{i \in I_{au}} (r_{u,i} - \bar{r}_u)^2}} \quad (2)$$

Notar que solamente se consideran los ítems que pertenecen al conjunto I_{au} , que describe a los ítems que han sido calificados por los usuarios a y u a la vez.

Cabe destacar que existen dos aproximaciones en la implementación de este algoritmo: La aproximación basada en ítem, que busca similitud entre ítems (comparando los ratings entre ítems -columnas en la Figura 1-), y que provee recomendaciones más precisas si el número de usuarios excede el de ítems disponibles; y la aproximación basada en usuario, que busca similitud entre usuarios (comparando los ratings entre usuarios - filas en la Figura 1), y que provee recomendaciones más originales, que pueden guiar al usuario a una experiencia mucho más satisfactoria. Las ecuaciones (1) y (2) corresponden a la aproximación basada en usuario.

2.1.1.3. Filtrado Híbrido (Hybrid Filtering)

El filtrado híbrido es una solución a las falencias en diversos aspectos que presentan las técnicas ya descritas. Por ejemplo, el filtrado basado en contenido tiene una desventaja sobre los datos conocidos de los ítems, ya que la información disponible de los ítems, metadatos, puede ser escasa o poco descriptiva y, por consiguiente, las recomendaciones resultan poco precisas; esto se conoce como Análisis de Contenido Limitado.

Mientras que, el filtrado colaborativo presenta varios problemas, los más importantes como Comienzo Frío (Cold Start) que ocurre cuando el usuario al que se desea dar recomendaciones no ha realizado suficientes ratings, por lo que no se pueden determinar sus preferencias, y la Escasez de Datos, que ocurre cuando no existe información necesaria para realizar recomendaciones, por ejemplo, al haber una muy baja tasa de ratings general.

Entonces, el filtrado híbrido es una combinación de las técnicas descritas anteriormente, para explotar los beneficios y aminorar los problemas de cada una de ellas. Existen diferentes propuestas que permiten combinar estas técnicas de diferentes maneras, tales como las descritas en (Burke, 2007).

2.1.2. Sistemas de Recomendación Conscientes del Contexto (CARS)

Las aproximaciones tradicionales de RS consideran solo dos tipos de entidades como parte de la problemática de recomendación, usuarios e ítems, pero no son conscientes de la influencia del contexto sobre el usuario al momento de decidir por un ítem. Por ejemplo, el tiempo, localización, estado de ánimo o la compañía de otra persona (Adomavicius et al., 2011; Adomavicius & Tuzhilin, 2005a).

Entonces, es importante incorporar esta información contextual en el proceso de recomendación, con el fin de sugerir ítems apropiados bajo ciertas circunstancias (Adomavicius & Tuzhilin, 2005b). Un ejemplo de la importancia del contexto, es considerar las estaciones del año en un RS sobre turismo que provee distintos destinos dependiendo si es invierno o verano. Estos sistemas son llamados Sistemas de Recomendación Conscientes del Contexto (CARS, por su sigla en inglés de *Context-Aware Recommender Systems*).

Los CARS se han estudiado desde principios de la década del 2000, desarrollando investigaciones académicas en diferentes dominios (Adomavicius et al., 2011).

Es importante distinguir que contexto es un concepto amplio que ha sido estudiado a través de diferentes disciplinas de investigación, incluyendo Ciencias de la Computación, inicialmente en Inteligencia Artificial y Computación Ubicua (Ubiquitous Computing).

En el diccionario Webster se define el concepto de contexto como “circunstancias o condiciones que afecta alguna cosa”; sin embargo, es en (Dey, 2001), donde se define apropiadamente de la siguiente manera: “Contexto es cualquier información que puede ser usada para caracterizar la situación de una entidad. Una entidad es una persona, lugar u objeto que sea considerado relevante para la interacción entre un usuario y una aplicación, incluyendo también al usuario y las aplicaciones”, además, se define una aplicación consciente del contexto de esta forma: “Un sistema es consciente del contexto si usa contexto para proveer información relevante y/o servicios para el usuario, donde la relevancia depende de la tarea del usuario”.

2.1.2.1. Aproximaciones de representación de información contextual

Desde sus inicios, la investigación en CARS se ha enfocado en problemas relacionados con la noción de rating como una forma de capturar las preferencias del usuario para diferentes ítems.

Esta especificación es conocida como *Sistema Tradicional* o *Bidimensional* (2D) ya que sólo se consideran esas dimensiones en el proceso de recomendación (Adomavicius et al., 2011).

$$R: \text{Usuario} \times \text{Item} \rightarrow \text{Rating} \quad (3)$$

En CARS se asume que la información contextual es definida por un conjunto de atributos contextuales, que afectan al rating. Entonces, la función R (Gediminas Adomavicius, Bamshad Mobasher, Francesco Ricci, 2011) es de la forma:

$$R: Usuario \times Item \times Contexto \rightarrow Rating \tag{4}$$

Donde *Contexto* especifica la información contextual conocida en la aplicación. La información contextual puede ser representada en una *estructura jerárquica* que puede ser vista como un árbol (Adomavicius, Sankaranarayanan, Sen, & Tuzhilin, 2005; Palmisano, Tuzhilin, & Gorgoglione, 2008). Por ejemplo, *tiempo* puede estar definida de la siguiente forma:




Figura 2: Ejemplo de estructura jerárquica de información de contexto dimensión Tiempo

Aquí, se asume que el contexto esta predefinido por atributos observables, con una estructura que no cambia significativamente en el tiempo. Más específicamente, se define la información contextual con un conjunto de dimensiones contextuales K (Adomavicius et al., 2005; Palmisano et al., 2008). Donde, los valores tomados por los atributos ubicados más abajo definen al nivel más fino (más granular), mientras que los valores ubicados más arriba definen el nivel más grueso (menos granular) de conocimiento contextual.

Por ejemplo, en la Figura 2 de taxonomía Tiempo mencionada arriba, Fecha es del nivel más granular de la jerarquía, mientras que Año es el nivel más grueso.

La información contextual también puede ser definida usando un modelo multidimensional de datos basado en OLAP⁵ (Adomavicius et al., 2005). En esta aproximación, los ratings son almacenados en cubos multidimensionales, donde se especifica por cada usuario, ítem y contexto, tal como se muestra en la Figura 3.




Figura 3: Información contextual en modelo multidimensional basado en OLAP (Adomavicius et al., 2005)

⁵ OLAP, sigla en inglés para Procesado Analítico En línea (OnLine Analytical Processing)

2.1.2.2. Paradigmas para Contextualización de Recomendaciones

Como ya se ha mencionado anteriormente, la forma general de un RS tradicional (2D) ($Usuario \times \acute{I}tem$) puede ser descrito como una función, que toma parte de los datos de preferencias del usuario como entrada y produce una lista de recomendaciones para cada usuario. En la Figura 4 se muestra una representación del proceso de recomendación tradicional.



Figura 4: Componentes generales del proceso de recomendación tradicional (2D) (Adomavicius et al., 2005)

Como se puede ver en la Figura 4, los datos de entrada de un RS tradicional son de la forma $\langle usuario, ítem, rating \rangle$. Mientras que, los CARS están basados en el conocimiento de las preferencias contextuales del usuario, que tienen la forma $\langle usuario, ítem, contexto, rating \rangle$, donde se especifica las preferencias del usuario respecto a un ítem en particular, y también el contexto asociado a dicha preferencia. Entonces, la información contextual se expresa en la forma $U \times I \times C \times R$, donde C es una dimensión de contexto adicional. El proceso de recomendación en este caso termina con una lista de recomendaciones contextuales $\langle \acute{i}_1, \acute{i}_2, \acute{i}_3, \dots \rangle$ para cada usuario.

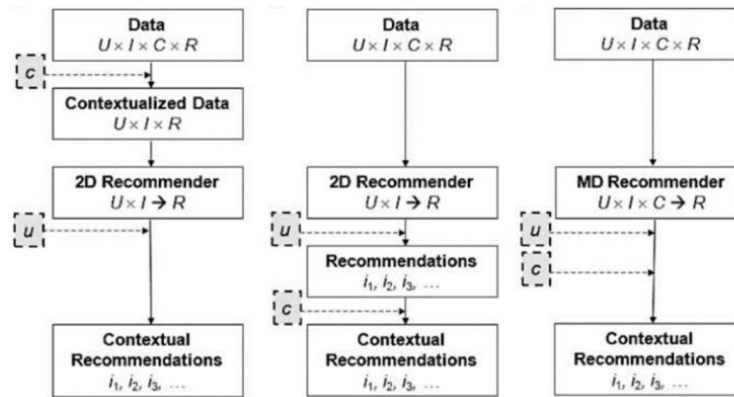


Figura 5: Paradigmas para la incorporación de información de contexto en RS (Adomavicius et al., 2005).

(a) Pre-filtrado contextual, (b) Post-filtrado contextual, (c) Modelado contextual

Una clasificación ampliamente utilizada en ámbito de CARS, propuesta por Adomavicius et al. (Adomavicius et al., 2005) para incorporar información contextual en el proceso de recomendación, distingue los siguientes esquemas de contextualización de recomendaciones: *Pre-filtrado contextual*, *post-filtrado contextual* y *modelado de contexto*. A continuación, se profundiza en las características y ventajas de cada uno de los tres paradigmas.

2.1.2.2.1. Pre-filtrado Contextual

El pre-filtrado contextual usa la información contextual para seleccionar los datos más relevantes 2D ($Usuario \times Ítem$) para generar recomendaciones, según el contexto objetivo (para el cual se desea la recomendación). Su principal ventaja es que permite utilizar cualquier técnica tradicional para recomendación (Adomavicius & Tuzhilin, 2005b). Una opción es usar la información contextual c como *consulta* para seleccionar datos relevantes de ratings, por ejemplo, si un usuario quiere ver una película un sábado, entonces sólo serán usados los datos de ratings hechos en sábados para recomendar una película.

Como ejemplo de pre-filtrado contextual, la aproximación basada en reducción (Adomavicius et al., 2005), consiste en reducir el problema siguiendo la forma de la función de estimación tradicional 2D. Se puede añadir una dimensión de contexto, por ejemplo tiempo, dejando la función de estimación $R_{Usuario \times Ítem \times Tiempo}^D: U \times I \times T \rightarrow Rating$, donde el conjunto D contiene $\langle Usuario, Ítem, Tiempo, Rating \rangle$. Entonces la función tridimensional es:

$$R_{Usuario \times Ítem}^{D[Tiempo=t]}(Usuario, Ítem, Rating)(u, i) \quad (5)$$

Donde $[Tiempo = t]$ denota el pre-filtro contextual de todos los ratings realizados en el contexto exacto t , por ejemplo, el contexto exacto $t = \text{sábado}$.

Por otro lado, existe la noción de pre-filtrado generalizado (Adomavicius et al., 2005), permite generalizar la consulta de filtrado de datos obtenida a través de un contexto específico.

De esta manera, la generalización de contexto (Adomavicius et al., 2005) propone cambiar el pre-filtro exacto $[Tiempo = t]$ a un pre-filtro más general $[Tiempo \in S_t]$, donde S_t (segmento contextual) denota alguna categoría sobre el contexto t .

Entonces, si un usuario quiere ver una película un sábado, no es necesario pre-filtrar exactamente por el valor sábado, en cambio, se puede generalizar a *Vez_Semana* usando el valor de $S_t = Fin_Semana$, de esta forma la función R es:

$$R_{Usuario \times Ítem}^{D[Tiempo=S_t]}(Usuario, Ítem, AGGR(Rating))(u, i) \quad (6)$$

Cabe notar que $AGGR(Rating)$ es la sumariación de los datos de ratings respecto al valor S_t escogido, en este ejemplo, la sumariación contendría los ratings con valores de contextos $t = \text{sábado}$ y $t = \text{domingo}$.

Finalmente, el resultado de la función R tradicional 2D, aplicada sobre los datos de Usuario e Ítem, es una lista de recomendaciones de ítems ajustada a la información de contexto especificada.

2.1.2.2.2. Post-filtrado Contextual

El post-filtrado contextual ignora la información de contexto como dato de entrada, y genera la lista de recomendaciones de ítems usando un método tradicional (2D). Luego, esta lista se ajusta usando la información de contexto. Este ajuste puede ser realizado: filtrando las recomendaciones irrelevantes (respecto al contexto), o ajustando el ranking de recomendaciones en la lista (basado en el contexto dado). Al igual que la aproximación de pre-filtrado contextual, la mayor ventaja de esta aproximación es la libertad de usar cualquier técnica de recomendación tradicional ya desarrollada.

El post-filtrado contextual puede ser clasificado en técnicas heurísticas, que trata de obtener características en común (atributos) para un usuario dado en un contexto dado, y luego usar estos atributos para ajustar las recomendaciones; y basadas en modelo que pueden construir modelos predictivos que calculan la probabilidad de relevancia, y usan estas probabilidades para ajustar las recomendaciones.

Finalmente, se provee de una lista de recomendaciones de ítems que está ajustada a la información de contexto especificada.

2.1.2.2.3. Modelado Contextual

La aproximación de modelado contextual usa la información contextual directamente en la construcción de un modelo de recomendación como un predictor explícito de ratings. A diferencia de las aproximaciones anteriores, este paradigma entrega una verdadera función de recomendación multidimensional que incorporan contexto (Adomavicius & Tuzhilin, 2005b).

Existen varios algoritmos propuestos en la literatura para cada una de los paradigmas antes descritos, por ejemplo modificaciones para la versión tradicional (2D) con criterio de separación (Splitting Criteria) (Baltrunas & Amatriain, 2009; Baltrunas & Ricci, 2009; Zheng, Burke, & Mobasher, 2014) en el caso de pre-filtrado contextual, un esquema de ponderaciones para descartar ítems menos relevantes a un contexto (weighted post-filtering) para el caso de post-filtrado contextual, e incorporación de contexto en matriz de factorización (Baltrunas, Ludwig, & Ricci, 2011; Karatzoglou, Amatriain, Baltrunas, & Oliver, 2010; Koren, 2008) para el caso de modelado contextual.

2.1.3. CARSKit: Librería Especializada en CARS

La librería especializada CARSKit, es un motor de recomendación conscientes del contexto, que posee una amplia gama de algoritmos de recomendación tradicionales y conscientes del contexto, y además, provee métricas de error y ranking para la evaluación de estos algoritmos de recomendación (Zheng, 2015).

El propósito de usar esta librería, es garantizar un procedimiento estándar para el proceso de recomendación, asegurar la calidad de los resultados de las métricas de evaluación y facilitar la obtención de algoritmos tanto tradicionales y contextuales para la experimentación.

Los **Algoritmos Baseline** se componen de algoritmos de recomendación tradicionales, es decir, que no contemplan la información de contexto en su proceso de recomendación. Estos algoritmos entregan resultados para cada métrica de evaluación con el fin de ser la base de referencia para comprobar la efectividad de las contribuciones de esta tesis. Los algoritmos considerados como Baseline son: UserKNN, ItemKNN y BiasedMF.

El algoritmo **UserKNN** es una aproximación de filtrado colaborativo que genera una predicción de rating de un usuario u sobre un ítem i en base a los ratings de otros k usuarios similares, llamados vecinos (Resnick et al., 1994). El procedimiento de este algoritmo ha sido explicado más a fondo en la sección 2.1.1.2.

Así mismo, el algoritmo **ItemKNN** es una aproximación que genera la predicción de rating de un usuario u sobre un ítem i en base a los ratings que otros k ítems similares (Resnick et al., 1994; Sarwar, Karypis, Konstan, & Reidl, 2001). Esta aproximación utiliza el mismo procedimiento que es usado en UserKNN, con la diferencia que la comparación de los k vecinos se realiza con el conjunto de ratings de ítems en lugar de los usuarios.

Por otro lado, el algoritmo **BiasedMF** es una aproximación basada en Factorización de Matrices (Goldberg et al., 1992; Hu, Koren, & Volinsky, 2008; Koren, Bell, & Volinsky, 2009), que descompone la matriz de ratings en vectores q_i , asociados cada ítem i , y vectores p_u , asociados a cada usuario u . Con estos vectores, se puede predecir todos los ratings para cualquier usuario sobre un ítem \hat{r}_{ui} con mucha precisión a través del producto de los elementos de cada vector, tal como se presenta en la ecuación (7).

$$\hat{r}_{ui} = q_i^T p_u \quad (7)$$

Esta aproximación, también considera la variación de los ratings independientemente del cálculo anterior. A estas variaciones se les conoce como sesgo o *bias*, que representan ratings que tienen valoraciones muy altas o muy bajas; por ejemplo, un ítem que ha sido muy famoso y recibe valoraciones sobre lo normal, haciendo que la predicción para este ítem sea equivocada.

Por esta razón, se ha introducido en el cálculo de la predicción de \hat{r}_{ui} , un valor de compensación de sesgos de la forma $b_{ui} = \mu + b_i + b_u$, donde μ representa la puntuación global de todos los ratings, b_u y b_i representan las desviaciones del usuario y del ítem de esa media global. De esta forma, la ecuación adopta de la siguiente manera:

$$\hat{r}_{ui} = \mu + b_i + b_u + q_i^T p_u \tag{8}$$

Luego, para realizar el cálculo completo de predicciones de ratings para cada usuario sobre un ítem, se realiza un procedimiento de entrenamiento del modelo, buscando minimizar el error cuadrático e incorporando un factor de regulación λ , que evita el efecto de sobreentrenamiento, limitando la cantidad de iteraciones realizadas en la fase de entrenamiento.

$$\min_{p^*, q^*, b^*} \sum_{(u,i) \in K} (r_{ui} - \mu - b_i - b_u - q_i^T p_u)^2 + \lambda (\|p_u\|^2 + \|q_i\|^2 + b_u^2 + b_i^2) \tag{9}$$

Finalmente, el algoritmo de BiasedMF propone un cálculo mucho más preciso de la predicción de rating, ya que incorpora distintos niveles de control de variaciones e imprecisiones en las valoraciones, tal como se muestra en la ecuación (9).

Por su parte, los **Algoritmos Conscientes del Contexto** hacen uso de la información de contexto presente en los ratings para generar recomendaciones más personalizadas (ver sección 2.1.2). Así como, los algoritmos Baseline son una base de referencia, estos algoritmos conscientes del contexto son el objetivo a comparar, con el fin de probar que el uso de una taxonomía manual de información de contexto beneficia de forma directa al proceso de recomendación. En esta experimentación se usan tres tipos de aproximaciones: Splitting, CAMF y SPF.

Los algoritmos de tipo **Splitting** son una aproximación que realiza un procedimiento de pre-procesamiento de los datos según las condiciones contextuales, para luego aplicar algoritmos de recomendación tradicionales. Es decir, que luego de este pre-procedimiento se obtiene una matriz de ratings sin información contextual donde es posible aplicar un algoritmo de recomendación tradicional, tales como UserKNN, ItemKNN y BiasedMF explicados anteriormente.




Figura 6: Efecto de la aproximación ItemSplitting en la matriz de ratings

La primera aproximación de tipo Splitting es **ItemSplitting** (Baltrunas & Ricci, 2009), que consiste en separar el conjunto de ratings de ítems de acuerdo un valor determinado de contexto, con el fin de simular una matriz de sin información contextual, donde se pueda aplicar un algoritmo tradicional de recomendación, tal como se muestra en la Figura 6. Es decir, el algoritmo busca en cada ítem i , de la matriz de ratings de tamaño $m \times n$ (m usuarios y n ítems), el valor nominal de contexto $c_j \in (c_1, \dots, c_n)$ que es el conjunto de todos los valores de contexto en la matriz; por ejemplo, en la Figura 6, el contexto es *clima*, donde los valores son *despejado* y *nublado*. Si el ítem i posee ratings con valor de contexto c_j , entonces es posible crear dos ítems artificiales i_1 e i_2 que pertenecen al conjunto de ratings del ítem original i ; donde i_1 posee el conjunto de todos los ratings asociados al contexto c_j , e i_2 posee el conjunto del resto de ratings del ítem que no están asociados a dicho valor de contexto.

Para que la operación de Splitting se realice, primeramente, se debe comprobar que ambos subconjuntos de ratings tengan una suficiente diferencia estadística a través de un *criterio de impureza t* (*impurity criteria*). En (Baltrunas & Ricci, 2009), se consideran los siguientes criterios: t_{mean} , t_{prop} , t_{size} , t_{IG} y t_{random} ; cada uno de estos criterios busca comprobar que los dos subconjuntos i_1 e i_2 son independientes el uno del otro. En particular, el criterio t_{mean} estima cuan diferentes son los ratings del promedio de ratings en cada uno de estos dos subconjuntos.

$$t_{mean} = \left| \frac{\mu_{i_1} - \mu_{i_2}}{\sqrt{S_{i_1}/n_{i_1} + S_{i_2}/n_{i_2}}} \right| \quad (10)$$

En la ecuación (10), μ_{i_1} y μ_{i_2} representa la media de los ratings en los subconjuntos de ítems i_1 e i_2 respectivamente. Así también, los términos S_{i_1} y S_{i_2} representan la varianza de los ratings de los subconjuntos de ítems i_1 e i_2 respectivamente. Finalmente, n_{i_1} y n_{i_2} representan el número de ratings de cada subconjunto de ítems i_1 e i_2 respectivamente.

Considerando este criterio, mientras más alto sea el valor t , más grande será la diferencia estadística entre los subconjuntos de ítems i_1 e i_2 . En este caso, es necesario definir un valor umbral d que asegure el nivel mínimo de diferencia estadística, de tal forma que se cumpla la siguiente expresión $t_{mean}(i, c) > d$. Si se sobrepasa el valor umbral d , es debido a que estos subconjuntos son independientes entre ellos, y entonces se crean estos dos subconjuntos artificiales de ítems i_1 e i_2 en la matriz de ratings, añadiendo dos columnas en reemplazo de la columna del ítem original i , por lo que las dimensiones de la matriz cambian a $m \times (n + 1)$.

Finalmente, esta nueva matriz es utilizada en el proceso de recomendación por un algoritmo tradicional.

Análogamente, es posible modificar esta aproximación de ItemSplitting, considerando la información desde el punto de vista de los usuarios como se expone en la aproximación de *Micro-Profile* o **UserSplitting** (Baltrunas & Amatriain, 2009). Otra aproximación basada en Splitting es **UserItemSplitting** (Zheng et al., 2014), que mezcla las características de ItemSplittings y UserSplitting, dividiendo el conjunto de ítems y de usuarios de acuerdo a un valor de contexto especificado.

Alternativamente, el paradigma de Modelado Contextual utiliza la información de contexto en el proceso de recomendación a través de la incorporación de los valores de contexto en el cálculo de las predicciones de ratings (ver sección 2.1.2.2.3). Una aproximación de este tipo es **CAMF (Context-Aware Matrix Factorization)**, o factorización de matrices consciente del contexto, es una técnica extendida de MF tradicional, que incorpora información de contexto directamente en el modelo de predicción de rating (Baltrunas et al., 2011; Koren, 2009).

En este tipo de algoritmos, existen distintos modelos que pueden ser implementados según los parámetros a considerar en la predicción de ratings, tales como los ratings por usuario o por ítem, en general o considerando ambas unidas.

La aproximación **CAMF_C** (Baltrunas et al., 2011) es el modelo más simple de ellos, donde se asume que la influencia de la información contextual es uniforme para todos los ratings. Por lo que, existe un solo valor de forma B_{jc_j} incidiendo en la predicción de rating de la siguiente forma:

$$\hat{r}_{ui} = \bar{r} + b_u + q_i^t p_u + \sum_{j=1}^k B_{jc_j} \quad (11)$$

En la ecuación ((10), se presenta la función de predicción usada por el algoritmo CAMF, donde \bar{r} representa el valor medio del ítem, b_u representa la desviación del usuario u , mientras que $q_i^t p_u$ representa la interacción del usuario y el ítem. Así, el valor B_{jc_j} influye uniformemente en la predicción de cada rating según el contexto asignado c_j .

Sin embargo, se puede refinar el modelo considerando que cada información contextual influye de forma directa a cada ítem de la matriz a través del factor B_{ijc_j} , a esta aproximación se le llama **CAMF_CI** (Baltrunas et al., 2011). De esta manera, la fórmula anterior queda de la siguiente forma:

$$\hat{r}_{ui} = \bar{r} + b_u + q_i^t p_u + \sum_{j=1}^k B_{ijc_j} \quad (12)$$

Análogamente, se puede considerar la información contextual en cada usuario en lugar de los ítems, esta aproximación es **CAMF_CU** (Odić, Tkalčić, Tasič, & Košir, 2012) que considera un modelo que se centra en la influencia de la información través del factor B_{ujc_j} en

$$\hat{r}_{ui} = \bar{r} + b_u + q_i^t p_u + \sum_{j=1}^k B_{ujc_j} \quad (13)$$

la siguiente expresión:

Otra variación, es la aproximación **CAMF_CUCI**, ya que este modelo combina las aproximaciones anteriores CAMF_CI y CAMF_CU, asumiendo que cada contexto afecta de forma diferente a los ítems y a los usuarios. De tal forma, que se consideran las expresiones B_{ijc_j} y B_{ujc_j} para realizar la predicción de ratings en la siguiente fórmula:

$$\hat{r}_{ui} = \bar{r} + b_u + q_i^t p_u + \sum_{j=1}^k B_{ijc_j} + \sum_{j=1}^k B_{ujc_j} \quad (14)$$

Estas aproximaciones de tipo CAMF, tienen la característica de centrarse en mejorar la predicción de los ratings, mientras que las aproximaciones de pre-filtrado buscan limpiar la matriz de ratings de información contextual.

Sin embargo, también existe una aproximación que incorpora un procedimiento de pre-filtrado y un algoritmo de modelado contextual. Esta aproximación se conoce como **SPF (Semantic Pre-Filtering)**, y consiste en explotar las relaciones semánticas entre las situaciones contextuales para encontrar el nivel óptimo de contextualización para construir modelos locales (Codina, Ricci, & Ceccaroni, 2013). Es decir, que dada una situación contextual se realiza un pre-filtrado que puede ser basado en los usuarios o ítems (*User-based* o *Item-based*), e incluye un modelo BiasedMF sobre todos los ratings que cumplen con el valor de contexto. De esta manera, las siguientes fórmulas describen el *peso de importancia de un contexto* para Item-based y User-based:

$$\text{Item-based:} \quad w_{ci} = \frac{1}{|R_{ic}| + \beta} \sum_{r_{uic} \in R_{ic}} (r_{uic} - b_{ui}) \quad (15)$$

$$\text{User-based:} \quad w_{cu} = \frac{1}{|R_{uc}| + \beta} \sum_{r_{uic} \in R_{uc}} (r_{uic} - b_{ui}) \quad (16)$$

En las formulas (15) y (16), los conjuntos R_{ic} y R_{uc} representan a los ratings del ítem i en el contexto c , y con el usuario u en el contexto c , respectivamente. El valor β es usado para compensar el valor de R_{ic} o R_{uc} cuando son pequeños, evitando alterar el resultado de la predicción. La expresión $r_{uic} - b_{ui}$ usada en Item-based y en User-based, está limitada a los ratings que pertenecen a los conjuntos R_{ic} y R_{uc} respectivamente, por lo tanto, esta expresión realiza un procedimiento de pre-filtrado contextual. Además, el término b_{ui} representa una predicción de tipo biasedMF (descrita anteriormente), por lo que, esta aproximación también incluye un algoritmo basado en modelo.

Esta aproximación optimiza las dimensiones de contexto utilizadas según peso de importancia a través de SVD, con el fin de obtener el nivel de contextualización que produzca la mejor precisión en la predicción de ratings.

Finalmente, estos algoritmos de recomendación son una parte de los algoritmos implementados en CARSKit que representan técnicas de recomendación comúnmente usadas en investigación en el ámbito de CARS.

2.1.4. Obtención de información de contexto

Un desafío mayor en la investigación en CARS es la falta de *datasets* con información de contexto (Li et al., 2010). La mayoría de estudios en el área típicamente utiliza pequeños *datasets* con información contextual obtenida de forma explícita, usualmente mediante cuestionarios que el usuario debe responder, lo cual implica una carga adicional para el usuario, que muchas veces no está dispuesto a sobrellevar. Por otro lado, gracias a la disponibilidad de dispositivos GPS en *smartphones* y otros dispositivos móviles, recientemente se han generado *datasets* que incluyen información de localización (en forma de coordenadas GPS) y de tiempo (en forma de marcas temporales o *timestamps*) (Sarwat, Levandoski, Eldawy, & Mokbel, 2014). Sin embargo, es difícil encontrar *datasets* con información sobre otras dimensiones contextuales, como quién acompaña al usuario o su estado de ánimo.

Debido a lo anterior, resulta relevante poder acceder a otras fuentes de información contextual. En este sentido, en algunos trabajos previos se ha planteado la extracción de

información de contexto desde fuentes textuales, como por ejemplo comentarios (*reviews*) en que los usuarios suelen describir sus experiencias con ítems de manera libre, en sitios de comercio electrónico tales como Amazon.com o Tripadvisor (Aciar, 2010; Bauman & Tuzhilin, 2014; Li et al., 2010). Por ejemplo, Aciar (Aciar, 2010) presenta un método para determinar la existencia (o no) de información contextual en reviews, mediante técnicas de clasificación y minado de texto. Sin embargo, no llega a identificar qué contextos o valores contextuales se encuentran presentes. Bauman y Tuzhilin (Bauman & Tuzhilin, 2014), proponen un método para extraer información de contexto desde reviews de restaurantes mediante dos esquemas de clasificación: uno basado en frecuencia, y otro basado en LDA (Blei, Ng, & Jordan, 2003). Sin embargo, en este trabajo se sigue la vista de interacción de contexto (Dourish, 2004), la cual asume la presencia de un valor de contexto latente de un conjunto de valores de contexto afectando las preferencias del usuario, pero no es posible identificar con certeza cual valor de contexto está afectando en aquel instante, ya que el contexto no es necesariamente observable o conocido; por lo que dificulta establecer posibles relaciones con la información de contexto obtenida.

Por otro lado, Li et al. (Li et al., 2010) introducen un método para extraer información de contexto desde reviews de restaurantes, considerando una categorización de la información contextual. En este trabajo, se contemplan cuatro dimensiones contextuales específicas: *Compañía* (personas que participan en el evento, por ejemplo, familia, amigos, etc.), *Ocasión* (ocasión del evento, por ejemplo, cumpleaños, aniversarios, etc.), *Tiempo* (especificación del momento del evento, por ejemplo, desayuno, almuerzo, cena), y *Localización* (enfocada en la ciudad en que ocurre el evento). Para la obtención de la información, se utilizan herramientas de Procesamiento de Lenguaje Natural y anotado semántico, tales como GATE⁶ y ANNIE⁷, complementadas con algoritmos específicos de *matching* de textos y clasificación.

Este esquema es similar al utilizado comúnmente en el área de Extracción de Información (Banko, Cafarella, Soderland, Broadhead, & Etzioni, 2007) específicamente en la tarea de Reconocimiento de Entidades (*Named Entity Recognition* - NER), referente al uso de *Gazetteers* o diccionario de entidades (también llamado *lexicon*) (Nadeau & Sekine, 2007), que en este caso corresponde a los diferentes valores de contexto en cada dimensión. El uso de este esquema permite obtener un importante volumen de información de contexto a partir de las reviews analizadas. Por otro lado, los resultados experimentales de este trabajo muestran que no se obtiene directamente una mejora en la calidad de las recomendaciones, sino que esto depende del algoritmo utilizado y la calidad de la información extraída (Li et al., 2010).

⁶ GATE: General Architecture for Text Engineering, disponible en <https://gate.ac.uk>

⁷ ANNIE: A Nearly-New Information Extraction System, disponible en <http://services.gate.ac.uk/annie>

2.1.5. Confianza (Trust) en Sistemas de Recomendación

Como una forma de resolver los problemas de ataques maliciosos en sistemas de recomendación de tipo FC, tales como la copia de perfiles de usuarios que son alterados para beneficiar a ciertos ítems (Moradi & Ahmadian, 2015), otros tipos de ataques en RS se describen en (O'Mahony, Hurley, & Silvestre, 2005), algunos autores han propuesto incorporar un indicador de confianza (trust) en la predicción de ratings (Massa & Avesani, 2004; Murphy & Murphy-Hill, 2010). Es decir, que la recomendación utiliza sólo ratings realizados por usuarios confiables para el usuario activo.

La *confianza (trust)* para un RS es una puntuación (binaria o en alguna escala) que expresa qué tan verídicos son los ratings hechos por un usuario según la percepción del usuario activo. Esta puntuación puede ser obtenida explícitamente a través del usuario activo, o puede ser inferida a través de métricas para determinar confianza.

Usualmente, la técnica usada es FC, que busca mejorar los resultados del método kNN, adaptando las fórmulas de predicción, sustituyendo los valores de similitud por los valores de confianza, y reduciendo la cantidad de usuarios a un grupo de usuarios confiables para el usuario activo.

En (O'Donovan & Smyth, 2005a) se presentan tres formas de incorporar el indicador de confianza en el algoritmo de recomendación. Los algoritmos usados como base son la fórmula del método de Resnick, y la fórmula del coeficiente de correlación de Pearson para el cálculo de similitud entre usuarios ($sim(a, u)$) (Resnick et al., 1994).

- **Ponderación basada en Confianza:** Esta aproximación combina los valores de confianza y de Similitud:

$$\hat{r}_{a,i} = \hat{r}_a + \frac{\sum_{u \in N} (r_{u,i} - \bar{r}_u) \times w(a, u, i)}{\sum_{u \in N} |w(a, u, i)|} \quad (17)$$

$$w(a, u, i) = \frac{2(sim(a, u))(trust^I(u, i))}{sim(a, u) + trust^I(u, i)} \quad (18)$$

La ponderación $w(a, u, i)$ que reemplaza la utilización de la función de similitud, incorporando el valor de confianza $trust^I(u, i)$ (confianza para el usuario u en el ítem i). De esta manera, cualquier similitud con otro usuario estará condicionada a la confianza que se tenga de este usuario, lo que se verá reflejado en la predicción.

- **Filtrado basado en Confianza:** Considera discriminar a los usuarios que no son confiables para el usuario activo dado un determinado umbral de tolerancia T .

$$\hat{r}_{a,i} = \bar{r}_a + \frac{\sum_{u \in N^T} (r_{u,i} - \bar{r}_u) \times \text{sim}(a, u)}{\sum_{u \in N^T} |\text{sim}(a, u)|} \quad (19)$$

$$N^T = \{u \in N^T : \text{Trust}^l(u, i) > T\} \quad (20)$$

- **Combinación de Filtrado y Ponderación basada en Confianza:** Esta aproximación utiliza ambas modificaciones anteriores.

$$\hat{r}_{a,i} = \bar{r}_a + \frac{\sum_{u \in N^T} (r_{u,i} - \bar{r}_u) \times w(a, u, 1)}{\sum_{u \in N^T} |w(a, u, i)|} \quad (21)$$

La predicción es realizada sobre un conjunto de usuarios pre-filtrado, y el valor de confianza tiene influencia en la predicción.

Estas aproximaciones redujeron los problemas de ataques que sufren los RS que utilizan FC, y se obtienen recomendaciones más precisas.

Una opción reciente en (Moradi & Ahmadian, 2015), obtiene una ponderación que evalúa y entrega un valor más ajustado. Esta aproximación estudia en profundidad el impacto de la utilización del valor de confianza $T_{a,u}$ que es calculado a partir de la distancia entre los usuarios a y u en una “red de confianza” basada en estos valores (Massa & Avesani, 2007; Moradi & Ahmadian, 2015).

En las aproximaciones de (O’Donovan & Smyth, 2005a) y de (Moradi & Ahmadian, 2015), los algoritmos integran el indicador de confianza de diferentes maneras. Además, logran disminuir el impacto de los problemas presentados en las técnicas tradicionales.

2.1.6. Evaluación de Sistemas de Recomendación

La evaluación de RS es un medio para medir el comportamiento de un RS, en cuanto a la calidad de las predicciones, el impacto de las recomendaciones, y analizar la conformación de las recomendaciones. Sin embargo, es complejo evaluar adecuadamente un RS, debido a la

amplia variedad de aproximaciones (Ricci, Rokach, & Shapira, 2015). Sin bien, no existe un estándar sobre evaluación de RS, es común usar algunas métricas para obtener algún punto de comparación entre aproximaciones.

Además, en la evaluación se deben considerar los conjuntos de datos a usar: *Conjunto de Entrenamiento (Training Set)* que es usado para ajustar modelos de Machine Learning, tales como los algoritmos de recomendación, donde los ratings están disponibles para que el algoritmo modifique su comportamiento para ajustar su predicción; mientras que, un *Conjunto de Test (Test Set)* comprueba la validez del modelo construido, ya que este conjunto es ocultado del algoritmo, con el fin de corroborar la calidad de sus predicciones (Herlocker, Konstan, Terveen, & Riedl, 2004). En este apartado, se revisarán algunas de las métricas usadas para la evaluación de RS.

- **Métricas de Error** (calidad de las predicciones de ratings)

- **MAE** (Mean Absolute Error): Es una métrica que obtiene un valor que representa cuán diferentes son las predicciones de los ratings reales (Shardanand & Maes, 1995). Esta métrica se representa a través de la siguiente fórmula:

$$MAE = \frac{\sum_{r_{u,i} \in Test} |\hat{r}_{u,i} - r_{u,i}|}{|Test|} \quad (22)$$

Donde, $\hat{r}_{u,i}$ representa la predicción de ratings para el usuario u sobre el ítem i , el conjunto $Test$ representa el conjunto de Test para el experimento y contiene a todos los ratings usados para probar la calidad de las predicciones del algoritmo en cuestión.

- **RMSE** (Root Mean Squared Error): Es una variación de MAE y representa la desviación estándar de MAE (Herlocker et al., 2004). Esta métrica explica cuán dispersos son los errores obtenidos en MAE a través de la siguiente fórmula:

$$RMSE = \sqrt{\frac{\sum_{r_{u,i} \in Test} (\hat{r}_{u,i} - r_{u,i})^2}{|Test|}} \quad (23)$$

- **Métricas de Ranking** (calidad del conjunto de recomendación)

Las métricas de Precisión y recall son las más populares para evaluar sistemas de recuperación de información (Herlocker et al., 2004).

- **Precision:** es un ratio que indica la proporción de los ítems recomendados y que se consideran relevantes respecto del número total de ítems recomendados. Este valor se calcula de la siguiente manera:

$$Pre@k = \frac{1}{|U|} \sum_{u \in U} \frac{|Rel_u@k|}{k} \quad (24)$$

Donde Rel_u representa el conjunto de los ítems relevantes para el usuario u , mientras que la expresión $Rel_u@k$ limita el conjunto a los que se encuentran dentro de los k primeros ítems entregados por el algoritmo de recomendación.

- **Recall:** es un ratio que indica la proporción de ítems y que se consideran ítems recomendados relevantes respecto del número total de ítems relevantes. Para calcular este ratio se ocupa la siguiente fórmula:

$$Rec@k = \frac{1}{|U|} \sum_{u \in U} \frac{|Rel_u@k|}{|Rel_u|} \quad (25)$$

En las métricas Precision y Recall suelen calcularse sobre una determinada longitud de lista de ítems recomendados ($Pre@k$ y $Rec@k$), por lo tanto, varía según la cantidad de ítems considerados en la lista; generalmente, se consideran los primeros cinco o primeros diez ítems de la lista de ítems recomendados para su cálculo.

- **MAP** (Mean Average Precision): es una métrica que cuenta el orden relativo de los ítems relevantes dentro del ranking de ítems recomendados. Para obtener esta métrica se debe calcular *Average Precision* para cada usuario de la siguiente manera:

$$AP(u)@k = \frac{1}{|Rel_u|} \sum_{n=1}^k Pre@n * (i_n \in Rel_u) \quad (26)$$

Donde se considera la precisión de un usuario de acuerdo al orden de la lista de ítems recomendados. Luego, MAP se obtiene recopilando el resultado por cada usuario de la siguiente forma:

$$MAP = \frac{1}{|U|} \sum_{u \in U} AP(u) \quad (27)$$

- **NDCG** (normalized Discounted Cumulative Gain): es una métrica que considera los distintos niveles de relevancia que puede existir en el conjunto de ítems relevantes, comparando que los ítems más relevantes correspondan a los primeros lugares de la

lista de ítems recomendados obtenidos del algoritmo. Esta métrica primeramente sobre cada usuario, y luego se recopila cada resultado.

$$DCG_u@k = \sum_{n=1}^k \frac{2^{Rel_u(i_n)} - 1}{\log(n + 1)} \quad (28)$$

$$nDCG@k = \frac{1}{|U|} \sum_{u \in U} \frac{DCG_u@k}{IDCG_u@k} \quad (29)$$

Donde $Rel_u(i_n)$ representa el grado de relevancia del ítem para el usuario u según su posición en la lista de ítems recomendados, mientras que $IDCG_u@k$ representa el ranking ideal para el usuario u .

- **AUC** (Area Under the ROC Curve): es una métrica que evidencia el comportamiento de la lista de ítems recomendados (Bradley, 1997). Esta medida es equivalente a la probabilidad de escoger aleatoriamente ítems relevantes en la lista de recomendación y la mínima estimación probabilística de pertenecer a los ítems no relevantes.

$$AUC = \frac{1}{|\mathcal{P}||\mathcal{N}|} \sum_{a_i \in \mathcal{P}} \sum_{a_j \in \mathcal{N}} I(f(a_i) > f(a_j)) \quad (30)$$

Donde $I()$ es una función que retorna el valor 1 si se cumple la condición expuesta, y el valor 0 en caso contrario. Los conjuntos $|\mathcal{P}|$ y $|\mathcal{N}|$ representan los ítems relevantes *positivos* e ítems no relevantes *negativos*. Mientras que representa la probabilidad de un elemento aleatorio de un conjunto.

Si la métrica tiene el valor 1, entonces significa que cada ítem relevante está posicionado en el tope de la lista de recomendación, y los ítems no relevantes están mucho más abajo en la lista. En caso de que se obtenga un valor 0.5, entonces indica que el ranking de la lista es aleatorio.

Estas métricas proporcionan una visión de la calidad de las recomendaciones realizadas para un grupo de usuarios de prueba, por ende, estos valores pueden variar dependiendo del grupo de usuarios seleccionado.

Capítulo 3

Modelado de información de contexto

Los Sistemas de Recomendación Conscientes del Contexto (CARS) proveen de recomendaciones diferenciadas según el contexto en que el usuario interactuará con el ítem. Variables contextuales como el tiempo, localización, estado de ánimo o la compañía de otra persona pueden influir en las preferencias de los usuarios con respecto a ciertos ítems (Adomavicius et al., 2011; Adomavicius & Tuzhilin, 2005a). Entonces, es importante incorporar esta información contextual en el proceso de recomendación, con el fin de sugerir ítems apropiados a las circunstancias del usuario (Adomavicius & Tuzhilin, 2005a).

Existen otros importantes tipos de sistemas para los cuales la información de contexto es relevante. Este es el caso de sistemas ubicuos, pervasivos y de entornos inteligentes, los cuales buscan la integración de los sistemas informáticos en el entorno de la persona y, por lo tanto, dependen de manera importante en información de contexto para adecuarse a dicho entorno.

Algunas aproximaciones, como la que presenta (Castelli et al., 2007), proponen que la información de contexto está determinada por el dominio de aplicación del sistema. Por esta razón, existen muchos modelos orientados a satisfacer los intereses de sus dominios, descartando información de contexto que puede ser útil para otras aplicaciones. De esta manera, existen modelos parcialmente completos para una diversidad de dominios.

En este capítulo, se presenta una revisión de modelos de información de contexto descritos en la literatura, que serán utilizados como base para definir una taxonomía genérica, independiente del dominio, de información de contexto, que pueda ser utilizada para extraer este tipo de información desde fuentes de texto.

3.1. Modelos de información contextual

A través de estudios en diferentes áreas de aplicación, se han propuesto diferentes aproximaciones para modelar la información de contexto, tales como los *Modelos de Marcas* y *Valores Clave* (Indulska, Robinson, Rakotonirainy, & Henriksen, 2003; Lum & Lau, 2002) y el *Modelado Enfocado en el Dominio* (Castelli et al., 2007). Sin embargo, las aproximaciones más usadas se presentan a continuación:

- **Modelos Objeto-Rol:** Está enfocado en crear suficientes modelos formales de contexto para soportar procesamiento de consultas y razonamiento. La aproximación Context Modelling Language (CML) está basado en Modelos Objeto-Rol (ORM, por su sigla en inglés Object-Role Modeling) (Halpin, 2001). La formalidad de ORM y la extensión CML hacen posible soportar un sencillo mapeo desde el modelo de contexto hacia una aplicación particular.
- **Modelos Espaciales:** El espacio es un contexto importante en los RS conscientes del contexto. De acuerdo con Dey et al (Dey, 2001), el espacio puede ser visto como un aspecto central de las entidades de contexto. La información de localización puede ser representadas en: (a) Coordenadas Geométricas, que entrega puntos o áreas en espacios métricos (como latitud, longitud y elevación sobre el nivel del mar), y (b) Coordenadas Simbólicas, que representa un identificador espacial, tal como un número de una sala, o el ID de una celda.
- **Modelos basados en Ontologías:** Las Ontologías son descripciones de conceptos y sus relaciones, es una representación simbólica de conocimiento basada en lógica y que permite el uso de procedimientos de razonamiento automático a través de lenguajes OWL (sigla en inglés de Ontology Web Language) y OWL-DL (sigla en inglés de OWL-Description Logic). Los modelos ontológicos de contexto explotan la representación y el poder de razonamiento para obtener un lenguaje más expresivo para contextos más complejos, proveer una semántica formal de datos de contexto, y es posible usar herramientas de razonamiento para corroborar la consistencia de los datos, además de reconocer nueva información de contexto (Bettini et al., 2010). Existen varias ontologías OWL que han sido propuestas para representar descripciones datos de contexto, entre ellas la más prominente son la ontología SOUPA (Chen, Perich, Finin, & Joshi, 2004) y la ontología CONON (Zhang, Gu, & Wang, 2005). Los modelos ontológicos OWL-DL de contexto han sido adoptados en varias arquitecturas conscientes del contexto; tales como, CoBrA (Chen, Finin, & Joshi, 2004) y SOCAM (Gu, Wang, Pung, & Zhang, 2004) que utilizan SOUPA y CONON respectivamente.

- **Modelos Híbridos:** Una alternativa es una representación híbrida, que permita representar diferentes tipos de conocimiento a través de los distintos modelos. Esta estrategia permite reducir el costo computacional a través de un razonamiento híbrido y minimizar las desventajas de los modelos ya mencionados (Bettini et al., 2010).

La Tabla 1 muestra un resumen de las técnicas de modelado utilizadas en los estudios revisados.

Técnicas de Modelado	Cantidad de Estudios	Referencias Estudios
Objeto-Rol	4	(Henricksen & Indulska, 2006; Lee & Meier, 2009; Malek, Laroussi, & Derycke, 2008; Xu & Dong, 2012)
Ontologías	26	(Antunes et al., 2012; Bandara, Wang, & Pahl, 2009; Bhargava, Krishnamoorthy, & Agrawala, 2012b, 2012a, Biamino, 2011b, 2011a; Biamino & Cena, 2011; Bobillo, Delgado, & Gómez-Romero, 2008; Christopoulou, Goumopoulos, & Kameas, 2005; Da, Roose, Dalmau, Nevado, & Karchoud, 2014; Dai & Xu, 2008; Ejigu, Scuturici, & Brunie, 2007; Henricksen & Indulska, 2006; Jaroucheh, Liu, & Smith, 2012; Lee & Meier, 2009; Min, Kim, & Cho, 2008; Najar, Saidani, Kirsch-Pinheiro, Souveyet, & Nurcan, 2009; Nassar, Karray, Kamel, & Sattar, 2012; Neto, Kudo, & da Graça Pimentel, 2006; Park, Park, Kim, & Kang, 2010; Paul-Stueve & Wachsmuth, 2012; Qin, Shi, & Suo, 2007; Sotsenko, Jansen, & Milrad, 2015; Stevenson, Knox, Dobson, & Nixon, 2009; Xu & Dong, 2012; Yu, Zhou, Yu, Park, & Ma, 2008)
Híbridas	5	(Henricksen & Indulska, 2006; Lee & Meier, 2009; Nassar et al., 2012; Park et al., 2010; Xu & Dong, 2012)
Otras	5	(Echtibi, Zemerly, & Berri, 2009; Jayaraman, Zaslavsky, & Delsing, 2009; Jones & O'Neill, 2009; Nassar et al., 2012; Yu et al., 2008)

Tabla 1: Técnicas de Modelado de Contexto en la literatura revisada

A continuación, se detalla cada técnica de modelado y las estructuras de representación de información contextual.

1. Modelado Objeto-Rol

Esta técnica de modelado simplifica el proceso de diseño usando lenguaje natural, así como diagramas intuitivos, donde se pueden presentar ejemplos y examinar la información en términos simples o en hechos elementales. Además, el modelo puede expresar conceptos con simpleza, tales como objetos y roles, proveyendo una aproximación conceptual para modelado (Halpin, 2001).

De esta manera, es posible también modelar información de contexto, considerando la representación abstracta de conceptos, construir una estructura jerárquica y una forma fácil de navegar entre las entidades.

En (Malek et al., 2008), se utiliza un modelado de contexto utilizando la notación CTT (Concur Task Tree), que permite obtener una composición de operadores temporales sobre tareas o actividades que están relacionadas en una estructura jerárquica. Esta aproximación modela la información de contexto en categorías que reflejan la interacción de personas en grupos de trabajo de un proyecto.

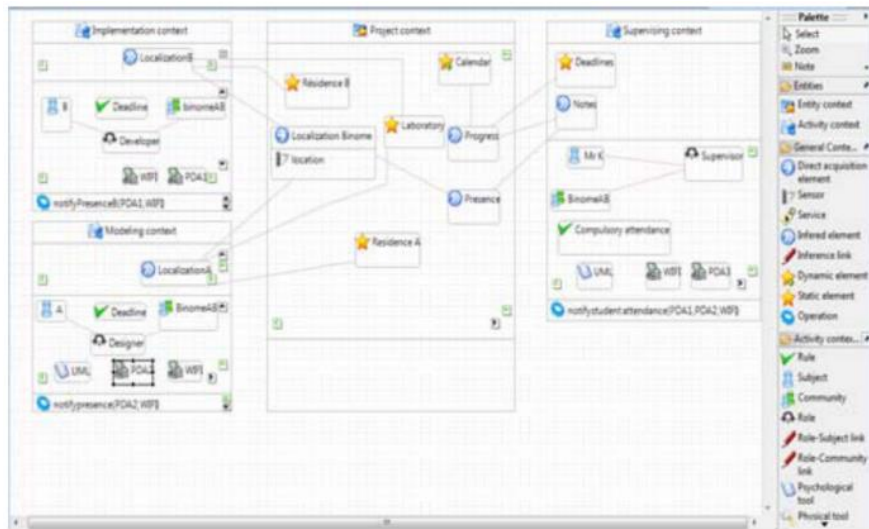


Figura 7: Representación modelo de contexto (Malek et al., 2008)

En la aplicación se propone una estructura para almacenar la información de contexto (ver Figura 7); cabe destacar, la similitud de este modelo visual con los diagramas UML, específicamente, un diagrama de clases. Sin embargo, esta estructura no presenta una jerarquía clara de información de contexto, limitándose a describir ciertas situaciones y características.

Por otro lado, en (Henricksen & Indulska, 2006) se presenta un software consciente del contexto que utiliza un modelo de contexto basado en CML. Esta aproximación indica la compatibilidad entre el modelado Objeto-Rol y la

implementación en un software, debido a que estos modelos pueden ser llevados a una base de datos relacional, donde es posible ejecutar consultas y establecer restricciones sobre la información de contexto.

2. Modelado Basado en Ontologías

Esta técnica de modelado utiliza ontologías que describen conceptos y sus relaciones a través de una semántica formal, usando el lenguaje formal OWL y su extensión OWL-DL. Estos modelos ontológicos usan herramientas de razonamiento con un lenguaje más expresivo para contextos más complejos, con el fin de corroborar la consistencia de la información y reconocer nueva información de contexto.

En (Biamino & Cena, 2011) se utiliza una ontología para representar el modelo de usuario. Esta ontología es una versión extendida de GUMO (General User Model Ontology, por sus siglas en inglés) (Heckmann, Schwartz, Brandherm, Schmitz, & von Wilamowitz-Moellendorff, 2005), la que a su vez incorpora FOAF (Friend Of A Friend) (Brickley & Miller, 2000), que permite modelar la información de usuario en un entorno ubicuo.




Figura 8: Estructura Jerárquica de dimensiones de contexto en GUMO

Como se muestra en la Figura 8, GUMO contiene cuatro dimensiones: *Basic User Dimensions*, *Domain Dimensions*, *Context Dimensions* y *Other Dimensions*. Para efectos de este estudio, son de mayor interés las tres primeras dimensiones de GUMO, debido a que la dimensión OTHER DIMENSIONS solamente contiene información sobre ratings, datos auxiliares y tipos de datos usados en GUMO.

El trabajo de (Bhargava et al., 2012a) utiliza la ontología OpenCyc, una ontología de código abierto, de conocimiento general del mundo y de razonamiento de sentido común. Es decir, esta ontología posee una base de conocimiento mucho más completa y compleja que la ofrecida por GUMO (ver Figura 9).

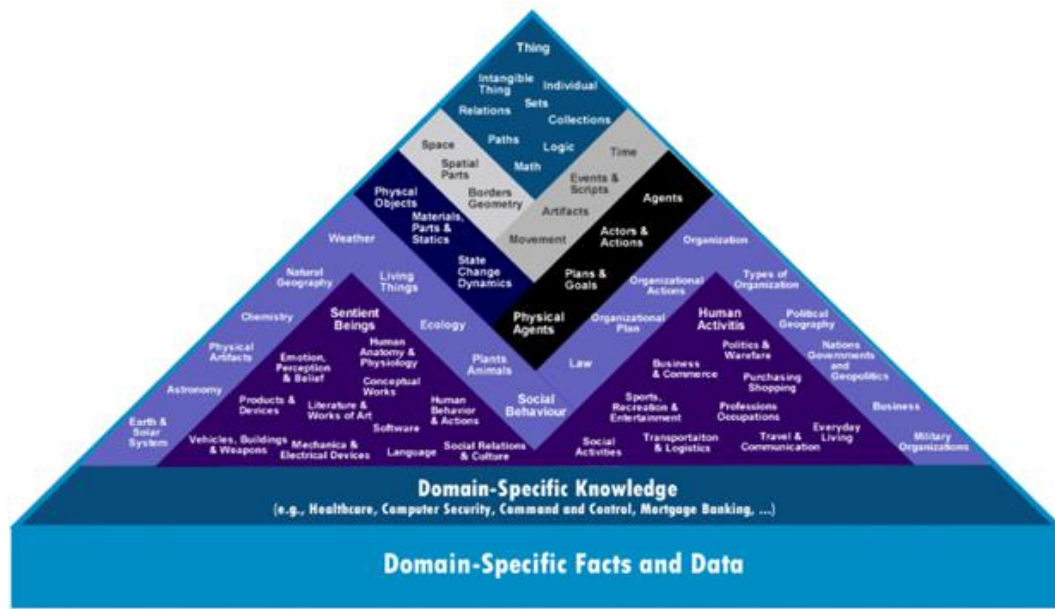


Figura 9: Estructura Jerárquica de Dominios OpenCyc

El desarrollo de sistemas inteligentes conscientes del contexto ha sido marcado con el uso de la técnica de modelado basado en Ontologías. En la revisión de la literatura solamente se encontraron cuatro estudios que utilizaran el modelado basado por rol de objeto; mientras que 26 estudios utilizaron el modelado basado en Ontologías (ver Figura 9). Esto debido a las ventajas que posee este tipo de modelado, como el razonamiento y la deducción de nueva información. Además, en el desarrollo de sistemas conscientes del contexto es muy valorado el uso de estructuras jerárquicas, característica principal de las ontologías.

3.2. Análisis de ontologías de información de contexto

El modelo Objeto-Rol es flexible para su implementación en software, pero la estructura utilizada para representar la información de contexto no es jerarquizada; además, esta estructura está guiada por el dominio de la aplicación, ignorando información de contexto no relevante para la aplicación (Halpin, 2001; Henriksen & Indulska, 2006; Malek et al., 2008).

En el caso de las aproximaciones de modelado basado en Ontologías, la ontología GUMO es considerada como una ontología situacional de un usuario, ya que identifica y modela al usuario, modela su entorno y sus relaciones, además, se le permite asignar un dominio de interés. De esta manera, es posible modelar de forma lógica a un individuo y su entorno en un ambiente ubicuo. Además, la estructura jerárquica de la información permite navegar entre las categorías para enriquecer y establecer razonamientos lógicos al modelo de usuario.

Por otro lado, GUMO no considera una dimensión Tiempo, lo que impide obtener modelos dinámicos de usuario. Considerando esto, la completitud en cuanto a la base de conocimiento es un tema importante, por lo que carecer de información de contexto impide modelar situaciones más complejas (Heckmann et al., 2005).

Alternativamente, OpenCyc permite modelar situaciones, entornos, objetos, individuos, grupos de individuos y sus atributos. La base de conocimiento de OpenCyc es uno de los recursos más completos que se han desarrollado sobre modelado de conocimiento general del mundo y su potencial en el desarrollo de aplicaciones es importante (Lenat, 1995; Lenat & Guha, 1989).

Sin embargo, la complejidad de su estructura, volumen y variedad de la información que posee OpenCyc es un problema para el desarrollo de aproximaciones a modelado de información contextual tal como se indica en (Bhargava et al., 2012a, 2012b; Bhargava, Krishnamoorthy, & Agrawala, 2015).

Finalmente, estas aproximaciones presentan varias ventajas, pero cada una de ellas presentan distintas desventajas, tales como, la aproximación de CML depende totalmente del dominio de la aplicación, el modelo GUMO tiene una estructura jerárquica rígida, y la Ontología OpenCyc posee una estructura muy compleja, que mezcla y relaciona diversas dimensiones de contexto, siendo necesario ocupar una aplicación para navegar en el gran volumen de instancias. Por lo tanto, considerando la estructura jerárquica de las aproximaciones de GUMO y OpenCyc, que están orientadas a representar una mayor cantidad y una mayor diversidad de información de contexto, se concluye que las aproximaciones basadas en ontologías son la mejor opción para la construcción de una Taxonomía de Información Contextual manual.

3.3. Dimensiones de información utilizadas en sistemas conscientes del contexto

La literatura revisada muestra una amplia variedad de dimensiones y variables de contexto representadas. Algunos de los trabajos agrupan esta información en grandes dimensiones (Biamino, 2011a; Biamino & Cena, 2011; Ejigu et al., 2007; Min et al., 2008; Xu & Dong, 2012). Cabe destacar, que algunos de los trabajos consideran a usuarios e ítems como contexto, sin embargo, en este estudio se entiende el contexto como toda información sobre las circunstancias que rodean la interacción de un usuario con un ítem, adicional al usuario e ítem.

La Tabla 2 muestra un resumen de las dimensiones y la información de contexto abordada en la literatura revisada.

Dimensiones	Información de Contexto	Estudios Relacionados
Tiempo	TimeStamp Rango Temporal Día de la Semana Horas del Día	(Bhargava et al., 2012a; Biamino, 2011b, 2011a; Biamino & Cena, 2011; Christopoulou et al., 2005; Da et al., 2014; Echtibi et al., 2009; Henricksen & Indulska, 2006; Jaroucheh

		et al., 2012; Jayaraman et al., 2009; Jones & O’Neill, 2009; Lee & Meier, 2009; Malek et al., 2008; Min et al., 2008; Najar et al., 2009; Nassar et al., 2012; Neto et al., 2006; Park et al., 2010; Qin et al., 2007; Stevenson et al., 2009; Xu & Dong, 2012; Yu et al., 2008)
Localización	Coordenadas GPS Proximidad de Datos Rango Espacial	(Bhargava et al., 2012a; Biamino, 2011b, 2011a; Biamino & Cena, 2011; Christopoulou et al., 2005; Da et al., 2014; Echtibi et al., 2009; Henricksen & Indulska, 2006; Jaroucheh et al., 2012; Jayaraman et al., 2009; Jones & O’Neill, 2009; Lee & Meier, 2009; Malek et al., 2008; Min et al., 2008; Najar et al., 2009; Nassar et al., 2012; Neto et al., 2006; Park et al., 2010; Paul-Stueve & Wachsmuth, 2012; Qin et al., 2007; Sotsenko et al., 2015; Stevenson et al., 2009; Xu & Dong, 2012)
Información de Usuario	Identidad / Entidad Estado (emocional) de Usuario Experiencia Historial de Logros Preferencias Disponibilidad Edad / Género /Profesión Aspectos de Personalidad Habilidades / Capacidades	(Bhargava et al., 2012b, 2012a, Biamino, 2011b, 2011a; Biamino & Cena, 2011; Echtibi et al., 2009; Ejigu et al., 2007; Jaroucheh et al., 2012; Jones & O’Neill, 2009; Najar et al., 2009; Nassar et al., 2012; Sotsenko et al., 2015; Stevenson et al., 2009; Xu & Dong, 2012)
Aspectos Sociales	Asociación entre personas Actividades / Eventos / Agenda Grupos de Contactos Tribu / Comunidad / Familia / Pareja / Club	(Bhargava et al., 2012b, 2012a, Biamino, 2011b, 2011a; Biamino & Cena, 2011; Echtibi et al., 2009; Ejigu et al., 2007; Henricksen & Indulska, 2006; Min et al., 2008; Neto et al., 2006; Paul-Stueve & Wachsmuth, 2012; Qin et al., 2007; Stevenson et al., 2009)
Entorno	Temperatura Clima Tráfico Vehicular Artefactos Médicos (Presión, Luz de sala, pulso, etc) Luminosidad Indicadores de Automóvil (Velocidad, Combustible, etc)	(Christopoulou et al., 2005; Da et al., 2014; Echtibi et al., 2009; Ejigu et al., 2007; Jayaraman et al., 2009; Lee & Meier, 2009; Malek et al., 2008; Nassar et al., 2012; Qin et al., 2007; Stevenson et al., 2009; Xu & Dong, 2012; Yu et al., 2008)

Aspectos de Sistema	Canales de Comunicación Dispositivos (Velocidad de Procesador, tamaño de pantalla, etc) Calidad de Servicios Functional / Semantic / Domain / Platform Clases / Interfaces / Métodos Historial (Llamadas, SMS)	(Antunes et al., 2012; Bandara et al., 2009; Bhargava et al., 2012b; Biamino & Cena, 2011; Dai & Xu, 2008; Ejigu et al., 2007; Henricksen & Indulska, 2006; Lee & Meier, 2009; Min et al., 2008; Neto et al., 2006; Park et al., 2010)
---------------------	---	--

Tabla 2: Dimensiones de contexto en estudios revisados

En la Tabla 2, se observa que las dimensiones de Tiempo y Localización son utilizadas en todos los estudios revisados. Mientras que el resto de dimensiones de contexto son utilizadas de manera menos frecuente. Esta diferencia es atribuible a la mayor facilidad para capturar información de tiempo y localización.

A continuación, se detalla el análisis de resultados y discusión sobre cada uno de estas dimensiones de contexto.

1. Dimensión Tiempo

La dimensión Tiempo representa un instante, rango o duración en unidades de tiempo. Estas unidades de tiempo pueden ser valores explícitos o referenciales, tales como una marca de tiempo (timestamp, que presenta una hora y fecha específica) o nombres de los momentos del día (ej. mañana, tarde y noche), estaciones del año o fechas especiales (ej. navidad o año nuevo) (Jayaraman et al., 2009; Najjar et al., 2009).

Este tipo de información es el más ampliamente usado, debido a que casi todos los dispositivos cuentan con un reloj digital incorporado que permite capturar marcas de tiempo. Además, a partir de esto se puede generar información más representativa a través de procedimientos simples, determinando por ej. momentos del día, día de la semana o estaciones del año tal como se presenta en (Jaroucheh et al., 2012).

La importancia de este tipo de información radica en la facilidad de trabajar con valores de tipo fecha, realizar cálculos y procedimientos estadísticos, con el fin de programar eventos, generar alertas, recomendar servicios o ítems ad-hoc al usuario (Echtibi et al., 2009).

En (Jones & O'Neill, 2009), la obtención de datos de esta dimensión es principalmente desde sensores como datos sin procesar desde el dispositivo (raw data). Sin embargo, existen aproximaciones como la planteada en (Min et al., 2008) que permiten capturar información de más alto nivel de contexto, a través de procedimientos de razonamiento. En (Najar et al., 2009) proponen una técnica de razonamiento que aprovecha su ontología de información de contexto para usar lógica de primer orden

considerando atributos, relaciones o valores, para descubrir nuevos contextos; por ejemplo, podemos considerar la siguiente regla $R(\text{Time}, =, \text{Saturday}) \rightarrow R(\text{Time}, =, \text{Weekend})$, entonces si el valor de contexto en la dimensión *Time* es *Saturday*, entonces se puede deducir que *Time* tiene el valor *Weekend* también, por lo que se recupera más información de contexto usando reglas de primer orden.

Los siguientes trabajos permiten apreciar el uso de información de dimensión tiempo en Sistemas inteligentes. En (Jaroucheh et al., 2012) usan la información de tiempo para organizar actividades de grupos de investigación de estudiantes de pregrado, postgrado y docentes, con el fin de optimizar los tiempos y coordinar los recursos en la universidad; mientras que en (Lee & Meier, 2009) utilizan la información de tiempo en *Itransit*, un sistema de monitoreo de tránsito de la Ciudad de Dublín, donde a través del procesamiento de datos, estiman el volumen de tránsito en momentos específicos y coordinan el sistema de semáforos, disminuyendo el tráfico vehicular.

2. Dimensión Localización

La información de la dimensión Localización representa posiciones, sectores, áreas, regiones, ciudades, países y datos de ubicación en general. Esta información puede ser representada como valores absolutos, tales como coordenadas GPS, bien como valores referenciales, tales como etiquetas (casa, oficina, etc.) (Jaroucheh et al., 2012).

Usualmente, las aplicaciones usan los datos sin procesar (raw data) de ubicación proporcionados por sensores GPS o por estimación de localización en base a dirección IP tal como se describe en (Echtibi et al., 2009); y a partir de ellos, en (Jayaraman et al., 2009) se genera información más compleja de ubicación por medio de un procedimiento de razonamiento que consiste en combinar valores de contexto de distintas dimensiones y deducir sobre la información disponible, por ejemplo, si se posee una *coordenada GPS*, una marca de tiempo establecida en la *noche* y una duración mayor a 8 *horas*, entonces se deduce que dado esos valores de contexto, se puede agregar que el usuario tiene un valor de ubicación *casa* u *hogar*, que es un valor más descriptivo.

Esta dimensión es importante, debido a la gran cantidad de dispositivos que poseen sensor GPS en smartphones, tablets, dispositivos en automóviles y otros dispositivos, que permiten obtener grandes volúmenes de datos de ubicación. Por esta razón, la información recopilada es muy versátil, siendo aprovechada por los sistemas para agendar eventos o acciones, recomendar servicios y rutas, o planificar el tráfico de una ciudad tal como se describe en (Lee & Meier, 2009).

Sin embargo, obtener esta información más descriptiva, tales como dirección, o bien determinar si una ubicación corresponde a casa, oficina, u otro tipo de lugar con un significado para el usuario, puede ser una labor más costosa.

Los siguientes trabajos muestran algunas aplicaciones que se desarrollan con el uso de esta dimensión de contexto. En (Echtibi et al., 2009) se presenta un software de ayuda a los turistas en Emiratos Árabes Unidos, que utiliza la ubicación GPS para sugerir lugares, o rutas turísticas según las preferencias del usuario; por otro lado, en (Dai & Xu, 2008) se utiliza una estimación de ubicación a través del análisis de sonido e imagen del interlocutor en una sala de reunión inteligente, con el fin de activar eventos a favor del buen desarrollo de la reunión según situaciones antes establecidas.

3. Dimensión Información de Usuario

La información de Usuario provee datos que describen solamente aspectos internos del usuario, es decir, posicionando el foco en la información que pertenece al usuario que puede afectar sus propias preferencias; por ejemplo, estado civil, nivel educacional, estados emocionales, habilidades o conocimiento (Biamino & Cena, 2011). En esta dimensión se excluye cualquier información sobre la interacción del usuario con otros individuos (ver Dimensión Aspectos Sociales).

Este tipo de información requiere de un entendimiento del comportamiento del usuario como ser humano (Ricci, Rokach, Shapira, & Kantor, 2015), debido a que muchos de estos aspectos pueden ser más complejos, como por ejemplo los psicológicos.

La dimensión de información de Usuario es importante para el proceso de recomendación, ya que influye en los gustos del usuario en un cierto momento. Por ejemplo, un usuario puede preferir una canción más lenta y suave cuando su estado emocional es de tristeza (Jaroucheh et al., 2012).

Obtener este tipo de información puede ser un desafío, ya que no existen sensores que logren capturar información psicológica directamente, aunque existen aproximaciones que infieren información a través de la combinación de diferentes datos. Aun así, recabar información del usuario requiere sensibilidad. Existe información que puede ser obtenida explícitamente a través de un cuestionario, tales como la fecha de nacimiento o el género (Echtibi et al., 2009). Mientras que otros tipos de información pueden ser obtenidos implícitamente a través del análisis de patrones o textos (Biamino, 2011a, 2011b; Echtibi et al., 2009).

En los estudios se utiliza la información de usuario para distintos propósitos. En (Park et al., 2010) usan esta información en un software simulador de sistema ubicuo para dispositivos móviles personalizando los servicios según el perfil del usuario. En cambio, en (Echtibi et al., 2009) obtiene la información explícitamente desde el usuario

a través de un formulario y de la interacción con las diferentes pantallas del dispositivo móvil, entregando recomendaciones de lugares turísticos en Emiratos Árabes Unidos. Finalmente, el trabajo en (Qin et al., 2007) ofrece una arquitectura que captura información de contexto de diferentes fuentes que alimentan un motor de inferencia usando un modelo basado en Ontologías y cálculos de probabilidades, con el fin de proveer servicios contextualizados en espacios (ambientes) inteligentes.

4. Dimensión de Aspectos Sociales

La dimensión de Aspectos Sociales reúne la información relacionada con la interacción del usuario con otros individuos. En esta dimensión se describe quien acompaña al usuario en un cierto instante de tiempo, sea este humano o de otro tipo, tales como familia, amigos, compañeros de trabajo o mascotas respectivamente (Biamino, 2011a, 2011b; Biamino & Cena, 2011; Ejigu et al., 2007).

Los aspectos sociales requieren la comprensión de los individuos con los que el usuario tiene contacto y relación (Biamino, 2011a). Muchas veces estos individuos pueden representar al entorno más común o el más ocasional, tales como la familia o desconocidos en el transporte público respectivamente.

La importancia de esta dimensión radica en que el usuario puede ser influenciado en sus decisiones por los individuos que lo acompañan (Biamino & Cena, 2011). Por ejemplo, el usuario puede decidir ver una película de comedia familiar al estar junto a su madre, pero podría escoger una película de terror en el caso de que se encuentre con algún amigo. Por lo tanto, la presencia de otro individuo puede alterar las preferencias del usuario.

Obtener este tipo de información puede ser bastante difícil de forma automática. Si bien podemos utilizar algunos sensores para detectar individuos en espacios inteligentes, aún sigue siendo un problema la identificación de los individuos dentro de ese determinado ambiente. Por otro lado, la forma más común es preguntar directamente al usuario por los individuos que lo acompañan, siendo una solución poco amable para el usuario. Otra de las formas de obtener información social es a través de procedimientos de inferencia y deducción descritas en (Ejigu et al., 2007).

Ejemplos de uso de información de aspectos sociales se muestran a continuación. En (Dai & Xu, 2008) se detectan las relaciones interpersonales con el fin de personalizar los servicios y la experiencia de los usuarios en un entorno inteligente, específicamente en una sala de reuniones. Mientras que, en los estudios (Biamino, 2011a, 2011b; Biamino

& Cena, 2011) se ha desarrollado un modelado de contexto enfocado en la información social, con el fin de mejorar el desempeño de objetos inteligentes⁸.

5. Dimensión Entorno

La dimensión Entorno recopila toda la información correspondiente a cualquier elemento del ambiente que pueda afectar las decisiones del usuario (Da et al., 2014; Nassar et al., 2012; Yu et al., 2008). Por ejemplo, información sobre el clima, tráfico vehicular e indicadores de sensores en habitaciones (ej: información de un termostato: temperatura o humedad), entre otros.

La importancia de esta dimensión radica en su estrecha relación con el dominio de la aplicación, siendo constantemente ocupada en procesos muy decisivos.

La obtención de información de entorno generalmente proviene desde sensores específicos (ej: termómetros, sensores de calor, sensor de ruido, etc.) e indicadores de otros sistemas (ej: estado del tráfico vehicular) (Dai & Xu, 2008). Además, es posible deducir situaciones desde los datos ya disponibles a través de Ontologías (Qin et al., 2007). Sin embargo, capturar información más representativa, tal como obtener contexto *calor* o *frio*, sigue siendo un desafío debido a la amplia variedad de contextos que se puede obtener, tal como se realizó en el caso de estudio presentado en (Christopoulou et al., 2005), donde se considera la temperatura corporal desde un termómetro para detectar la presencia de fiebre.

Esta información es usada de las siguientes formas. En (Dai & Xu, 2008) se captura información de entorno desde los sensores en la sala de reunión, tales como temperatura, nivel de luminosidad y ruido, para identificar a los interlocutores de la reunión, y por ende ofrecer modificar los parámetros para hacer la sala más adecuada a la realidad de la reunión. Por otro lado, en (Lee & Meier, 2009) se requiere de información de entorno referente al clima y al tráfico vehicular con el fin de proveer recomendaciones de rutas en la ciudad de Dublín (Irlanda) a sus usuarios.

6. Dimensión Aspectos de Sistemas

La dimensión de aspectos de sistemas es muy similar a la dimensión Entorno, sin embargo, difieren en que esta información corresponde al hardware, software, redes de comunicación y tipo de dispositivos con el que está interactuando el usuario con el sistema.

Esta información identifica los dispositivos y plataformas relacionadas con el sistema, con el fin de mejorar su rendimiento y la experiencia con el usuario. Si bien

⁸ Objetos Inteligentes (Biamino, 2011b): Cualquier dispositivo físico que puede ser potenciado por alguna plataforma basada en sensores y que pueda tener acceso a la base de conocimiento.

esta información no afecta de forma directa al usuario, en (Min et al., 2008) se indica que se puede influir en las recomendaciones debido a limitaciones con el dispositivo, por ejemplo, la versión del sistema operativo o no disponer de algún sensor específico (ej: GPS).

Los siguientes son ejemplos de uso de información de Aspectos de Sistemas. En (Bandara et al., 2009) se recopila la información sobre el contexto de Plataforma (de uso del usuario) con el fin de agilizar el proceso Web de Servicios de Negocios. Mientras que en (Ejigu et al., 2007) es necesario conocer la información del dispositivo, ya que, dependiendo del tipo y rendimiento de este, el sistema puede realizar acciones recomendadas en el dispositivo de acuerdo a la demás información de contexto.

Capítulo 4

Taxonomía para Anotación de Información Contextual

En este trabajo, se plantea obtener información de contexto de manera automática desde fuentes textuales correspondientes a diferentes dominios de recomendación. Para esto, se requiere de una base de conocimiento genérica que permita identificar información de contexto útil en diferentes dominios. Como se observó en la revisión de literatura sobre modelado de contexto, los modelos existentes en su mayoría se enfocan en un único dominio, descartando información que puede ser de interés en otros dominios. Por otro lado, existen algunos modelos genéricos, cuyo volumen de información resulta excesivo para lograr una adecuada identificación de información de contexto en el ámbito de Sistemas de Recomendación.

A partir de lo anterior, se propone la construcción de una taxonomía de información contextual, enfocada en dimensiones asociadas a circunstancias del usuario, aspectos sociales y de entorno, pues corresponden a la información más difícil de obtener mediante sensores u otros medios, siendo por tanto interesante su posible obtención desde fuentes textuales como comentarios de usuarios.

En este capítulo se presenta la taxonomía de información contextual desarrollada, y el proceso de anotación que, basado en la taxonomía, permite identificar y anotar información de contexto existente en comentarios de usuarios, de manera que sea útil para Sistema de Recomendación Conscientes del Contexto. La taxonomía propuesta se basa en la estructura presentada por GUMO (General User Model Ontology) (Heckmann et al., 2005), considerando además lo observado en la revisión de literatura sobre Modelado Contextual. Una característica que se busca con esta taxonomía es generar una adecuada jerarquización de la información contextual, que permita a los algoritmos de recomendación aglutinar (o separar) información en caso necesario.

4.1. Estructura de la Taxonomía

GUMO es una ontología de mediano nivel que permite modelar la información de usuario en un entorno ubicuo. La información contextual de GUMO está dividida en tres categorías: BASIC USER DIMENSIONS, CONTEXT-GUMO DIMENSIONS Y GUMO-DOMAIN DIMENSIONS. Estas categorías describen la información de usuario como individuo (tales como, personalidad, Estado Emocional y rol), la información contextual de la situación (referente a la localización o entorno social, entre otras dimensiones), y a la información de dominio de la aplicación (es decir, la información de interés respecto al área de desarrollo), respectivamente.

En la taxonomía propuesta en este trabajo se consideran tres tipos de información contextual: *Personal*, *Social* y *Environmental* (ver Figura 10). Estas dimensiones de contexto son altamente dinámicas y del suficiente interés del usuario para influir en sus preferencias, además, que por su naturaleza ha sido un desafío obtener información contextual de este tipo. Por otro lado, las dimensiones de contexto de Tiempo y Localización han sido estudiadas ampliamente, desarrollando variadas aproximaciones para identificar, deducir o calcular aquel tipo de información de contexto. Por lo tanto, se decidió concentrar el desarrollo en las tres dimensiones mencionadas con el fin de analizar de mejor manera el comportamiento de estas en los RS. A continuación, se describe y justifica cada una de las dimensiones de contexto incluidas en la propuesta.

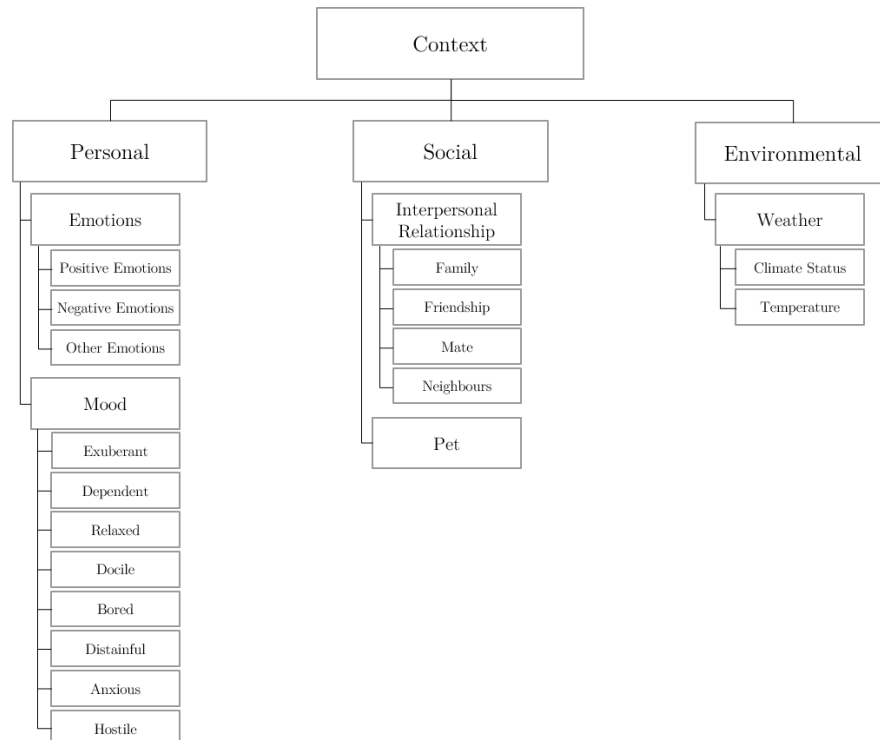


Figura 10: Estructura Jerárquica nueva Taxonomía de Información de Contexto

La dimensión *Personal* contiene la información del usuario con respecto a sus aspectos personales, tales como su estado emocional y anímico. Esta clasificación está tomada desde la estructura entregada por GUMO en BASIC USER DIMENSIONS. Sin embargo, solamente se han incluido las dimensiones *Emotions* y *Mood* en la propuesta, debido a que se consideró sólo la información dinámica y que, consecuentemente, se pueden considerar como contexto bajo la definición tomada en este estudio; se descartan las demás dimensiones de GUMO, ya que no fluctúan considerablemente en el tiempo, y por tanto corresponden más bien a características propias del usuario.

La categoría *Emotions* recuperada desde GUMO está organizada en base a la clasificación de emociones de Ekman (Ekman, 1973), sin embargo, esta clasificación presenta diversas falencias que impiden una correcta caracterización del usuario, la falencia principal es la preferencia de emociones negativas frente a las positivas (Mohammad & Turney, 2010). Debido a esta razón, se ha decidido utilizar la Clasificación de emociones de Plutchik (Plutchik & Kellerman, 1980; Plutchik, 2001), ya que provee un abanico más amplio y equitativo de emociones, y además, es la clasificación usada actualmente en los estudios en Análisis de Afecto (Mohammad & Turney, 2010).

Por otro lado, para obtener una estructura más jerarquizada que beneficie al proceso de recomendación, se utiliza la aproximación de EARL⁹ (Schröder, Pirker, & Lamolle, 2006) que provee una clasificación de 10 tipos de emociones (Negative and forceful, Negative and not in control, Negative thoughts, Negative and passive, Agitation, Positive and lively, Caring, Positive thoughts, Quiet positive, y Reactive). Con el fin de obtener grupos más grandes de emociones, se ha simplificado la clasificación en tres categorías: *Positive Emotions*, *Negative Emotions* y *Other Emotions*. Estas categorías combinan la clasificación de EARL coincidiendo con los conjuntos de emociones descritos por Plutchik, es decir, que incorporan las emociones básicas de Plutchik como subcategorías dentro de las categorías *Positive Emotions*, *Negative Emotions* y *Other Emotions*.

La categoría *Positive Emotions* se compone de las emociones clasificadas en Positive and lively, Positive Thoughts y Quiet positive proveídas por EARL. Las emociones recuperadas desde el modelo de Plutchik son: *Joy*, que a su vez contiene a *Serenity* y *Ecstasy*, *Trust*, que a su vez contiene a *Acceptance* y *Admiration*, además de *Delight* y *Hope*. Mientras que la categoría *Negative Emotions* se compone de las emociones clasificadas en Negative and forceful, Negative and not in control, Negative thoughts y Negative and passive proveídas por EARL. Las emociones recuperadas desde el modelo de Plutchik son: *Anger*, que contiene a *Annoyance*

⁹ HUMAINE Project (“HUMAINE Emotion Annotation and Representation Language,” n.d.)

y *Rage*, *Disgust*, que contiene a *Boredom* y *Loathing*, *Fear*, que contiene a *Apprehension* y *Terror*, *Sadness*, que contiene a *Pensiveness* y *Grief*, además de *Contempt*, *Anxiety*, *Pride* y *Despair*.

Por otro lado, la categoría *Other Emotions* se compone de las restantes emociones clasificadas en *Agitation*, *Caring* y *Reaction* proveídas por EARL. Las emociones recuperadas son: *Anticipation*, que contiene a *Interest* y *Vigilance*, *Surprise*, que contiene a *Distraction* y *Amazement*, además de *Love*.

De esta forma, estas categorías agrupan un amplio rango de emociones cercanas (y/o relacionadas) desde un nivel más general (categorías *Positive Emotions*, *Negative Emotions* y *Other Emotions*), luego usando las emociones básicas de la clasificación de Plutchik, y las emociones más específicas, además de incorporar emociones clasificadas como complejas por Plutchik, logrando una estructura más jerarquizada de emociones.

En la otra de las ramas de la categoría *Personal* está la clasificación *Mood*, que es recuperada íntegramente desde la estructura de GUMO y provee información sobre la actitud del usuario. Es decir, *Mood* representa las acciones del usuario con respecto a un estado emocional específico. Las actitudes encontradas en *Mood* son: *Exuberant*, *Dependent*, *Relaxed*, *Docile*, *Bored*, *Distainful*, *Anxious* y *Hostile*.

Otra de las categorías de más alto nivel es *Social*, que modela la información de contexto de la interacción de usuario con otras personas. Específicamente, esta categoría agrupa información sobre la compañía del usuario en un cierto instante. Las subcategorías de *Social* han sido adaptadas desde la dimensión *Social Environment* de GUMO-Context Dimensions. Las subcategorías son: *Interpersonal Relationship* que agrupa las categorías *Family*, *Friendship*, *Mate* y *Neighbour*; y *Pet*, que agrupa las dimensiones de *Cats*, *Dogs*, *Domesticated Birds* y *Horses*. A continuación, se describirá más a fondo ambas subcategorías.

La subcategoría *Interpersonal Relationship* permite modelar a persona(s) que esté(n) en compañía del usuario con el fin de obtener predicciones más personalizadas a la necesidad del usuario, y por lo tanto mejores recomendaciones.

La categoría *Family* ha sido adaptada desde GUMO, pero se han incorporado nuevos subniveles de información: *Nuclear Family* y *Extended Family*, descritos en (Murdock, 1949; Somerville, 1971). Esta incorporación se ha realizado con el fin de obtener información más jerarquizada para el proceso de recomendación.

La subcategoría *Nuclear Family* agrupa al núcleo familiar, es decir, a los familiares más cercanos. Por otro lado, la subcategoría *Extended Family* agrupa al resto de la familia.

Las categorías *Friendship*, *Mate* y *Neighbour* también han sido adaptadas desde la categoría Social Environment de GUMO. Cabe señalar que la categoría *Friendship* tiene como subcategoría *Best Friends*; mientras que *Mate* y *Neighbour* no tienen subcategorías.

La otra subcategoría dentro de *Social* es *Pet*. Esta categoría ha sido incluida en la taxonomía para incluir la capacidad de capturar información sobre mascotas que acompañan al usuario, cuya compañía puede influenciar los gustos de usuarios de sistemas de recomendación.

Finalmente, la categoría de alto nivel *Environmental* se compone de la información que pueda influir en el usuario desde su entorno. Por ejemplo, la información sobre clima puede alterar la elección del usuario sobre un ítem en algunos dominios. Esta categoría es una adaptación de la dimensión Physical Environment de GUMO-Context Dimensions, que considera solamente la categoría *Weather* y deshecha otras categorías desarrolladas para utilizar datos de sensores (no es del interés del actual trabajo).

La categoría *Weather* ha sido adaptada desde GUMO, incorporando más información con motivo de proveer una estructura más jerarquizada. Las subcategorías abarcan la información sobre clima en las siguientes categorías: *Climate Status*, *Weather Phenomena* y *Temperature*. Estas subcategorías han sido tomadas y reordenadas desde la estructura provista en DBpedia¹⁰.

La taxonomía propuesta provee una estructura jerarquizada, simple y escalable. Está compuesta por 78 categorías y tiene una profundidad máxima de hasta cinco niveles desde el nivel de dimensión. Además, esta taxonomía está basada (y adaptada) en la estructura dada por GUMO, incorporando ramas de categorías desde DBpedia y EARL, para ampliar la capacidad de identificación de información de contexto presente en documentos de texto.

4.2. Información incluida en la Taxonomía

Una vez establecida la estructura de la taxonomía, se añadió información correspondiente a palabras que representan posibles condiciones contextuales en cada una de las categorías incluidas en la taxonomía. Para ello, se utilizaron tres fuentes de información para incorporar información automáticamente. En primer lugar, se buscaron categorías equivalentes en DBpedia. En caso de existir la categoría en DBpedia, se añaden las instancias correspondientes a la taxonomía. En segundo lugar, se buscaron sinónimos tanto de la categoría como de las instancias añadidas en WordNet, las cuales fueron añadidas como categorías adicionales. En tercer lugar, se buscaron derivaciones en WordNet de las instancias añadidas

¹⁰ Base de conocimiento generada a partir de información disponible en Wikipedia, disponible en <https://dbpedia.org>.

previamente. A continuación, se describen brevemente los procesos de obtención de información aplicados en cada fuente.

4.2.1. Obtención de instancias en DBpedia

Para obtener información de instancias en DBpedia, se utilizaron consultas en lenguaje SPARQL¹¹ ejecutadas bajo el framework Apache Jena¹² que permiten, dada una categoría DBpedia, retornar las instancias correspondientes. Para ello, se aprovecha la estructura de DBpedia, pues gran parte de sus datos están expresados mediante el vocabulario SKOS (Simple Knowledge Organization System), el cual es un estándar de W3C (World Wide Web Consortium) para describir esquemas conceptuales tales como taxonomías. Esto permite recorrer el grafo de datos DBpedia utilizando diferentes relaciones entre conceptos. En particular, en este caso se utiliza la propiedad “dct:subject” que relaciona instancias y categorías. Así, para cada categoría en la taxonomía propuesta, se ejecutó una consulta por las instancias que existiesen en DBpedia para dicha categoría.

4.2.2. Obtención de sinónimos en Wordnet

Dado que para varias categorías de la taxonomía no se encuentran instancias en DBpedia, se incorporaron además sinónimos de la categoría (y de las instancias encontradas). Para ello, se utilizó la base de datos léxica WordNet. Mediante la API JAWS¹³, se implementaron consultas para retornar los “sinset” (conjuntos de sinónimos en WordNet) a los que pertenecen cada categoría, e instancias de DBpedia asociadas a dicha categoría en caso de haberlas.

4.2.3. Obtención de derivaciones en Wordnet

Para incorporar palabras correspondientes a otros posibles valores de contexto, también se incorporaron palabras derivadas, esto es, palabras con la misma raíz o lema, con una semántica relacionada, en diferentes categorías sintácticas. Para eso, se obtuvieron, para cada categoría e instancias previamente añadidas, palabras a partir de la relación “derivationally related forms” existente en WordNet, usando la API JAWS.

¹¹ SPARQL Protocol and RDF Query Language, lenguaje estandarizado par consulta de grafos RDF.

¹² Framework para construcción de aplicaciones basadas en Web Semántica en lenguaje Java, disponible en <https://jena.apache.org>.

¹³ Java API for WordNet Searching, disponible en <https://github.com/jaytaylor/jaws>.

4.2.4. Revisión manual

Finalmente, se realizó una revisión manual de las palabras añadidas de manera automática a cada categoría, con el fin de validarlas. El proceso de revisión manual se realizó en dos pasos: 1) se eliminaron aquellas palabras cuyo sentido no corresponde a posibles valores de contexto en la categoría correspondiente; y 2) se agregaron palabras que representan posibles valores de contexto en la categoría correspondiente, pero que no fueron incorporadas en el proceso automático.

De esta forma, la información recopilada en esta taxonomía ha sido revisada por completo, eliminando las instancias que desvirtúan el sentido de la información de contexto, y añadiendo manualmente las instancias que enriquecen la información de contexto en la estructura de la taxonomía. A continuación, se presentan la cantidad de instancias por dimensión de contexto y por el origen de la instancia.

Dimensión de Contexto	Origen de Instancias				Total
	DBpedia	Wordnet - Synonyms	Wordnet - Derivations	Manual	
Personal (45 categorías)	27	188	150	891	1256
Social (22 categorías)	20	30	17	316	383
Environmental (11 categorías)	1	4	1	232	238
Total	48	222	168	1439	1877

Tabla 3: Cantidad de instancias en la Taxonomía de Información Contextual

4.3. Identificación y anotación de información de contexto

Para identificar y anotar la información de contexto existente en fuentes textuales tales como comentarios de usuarios, en base a una taxonomía de contexto, se empleó un proceso de dos etapas, presentado en (Campos et al., 2017). En primer lugar, se emplean técnicas de

Procesamiento de Lenguaje Natural para seleccionar, entre todas las palabras existentes en el texto (comentario), aquellas que pudiesen representar información de contexto, a las que se denomina palabras candidatas. En segundo lugar, realiza un proceso de matching (emparejamiento) entre palabras candidatas y las palabras presentes en la taxonomía como posibles valores de contexto. Finalmente, se anotan los comentarios con la información de contexto encontrada en el paso anterior, anotando como variable de contexto la categoría de la taxonomía, y como valor de contexto la palabra con la que se encontró la coincidencia. A continuación, se describen brevemente los procesos de selección de palabras candidatas, y de matching de palabras.

4.3.1. Selección de palabras candidatas

El texto de un comentario puede contener muchas palabras, pero no todas contienen información de contexto. Para efectos de recomendación consciente del contexto, lo que interesa son las circunstancias que rodean a la experiencia del usuario con el ítem. Sin embargo, en un comentario, muchas veces se describen las características o contenido del ítem, en lugar de la experiencia con el mismo. En tal caso, intentar emparejar palabras del comentario con palabras de la taxonomía podría llevar a error. Por ejemplo, en una frase como “*this hotel welcomes pets*”, podría llevar erróneamente a establecer que parte del contexto de la experiencia del usuario del hotel fue que tenía como “compañía” a sus mascotas.

Debido a lo anterior, el primer paso corresponde a encontrar frases que potencialmente puedan contener información de contexto. A partir de una revisión manual de comentarios, se identificaron estructuras gramaticales que suelen ser empleadas cuando los usuarios describen sus experiencias con ítems. Éstas corresponden principalmente a frases escritas en primera persona (singular o plural). Esto incluye frases en que el sujeto es el pronombre “*I*” o “*we*”, o en que se utiliza un determinante posesivo de primera persona como “*my*”, “*mine*”, “*our*” o “*ours*”. Para identificar estas frases, se utilizó la librería Stanford CoreNLP (Manning et al., 2014), que implementa un conjunto de métodos de procesamiento de lenguaje natural. En particular, se utilizó la funcionalidad de *Part-of-Speech (POS) tagger*, que permite reconocer la categoría gramatical de las palabras.

Una vez seleccionadas las frases que pudiesen contener contexto, se seleccionan las palabras en ellas que pueden corresponder a valores de contexto. En general, se ha observado que los valores de contexto corresponden a palabras (en idioma inglés) de las categorías gramaticales **sustantivo** (por ejemplo: *parents*, *friends*, *pet*) o **adjetivo** (por ejemplo: *sunny*, *cloudy*, *happy*). Por ello, usando la librería Stanford CoreNLP se identifican las palabras candidatas a contener valores de contexto.

4.3.2. Matching de palabras candidatas y valores contextuales

Para cada palabra candidata, se debe establecer si corresponde a un valor contextual dentro de alguna de las categorías incluidas en la taxonomía. Para realizar este proceso de manera eficiente, se utilizó la librería Apache Lucene, que permite construir un índice de documentos para una búsqueda eficiente. De esta manera, por cada categoría de la taxonomía se crea un documento en Lucene, cuyo contenido es el conjunto de posibles valores de la categoría, los que corresponden a los valores añadidos (instancias en DBpedia, sinónimos y palabras derivadas en WordNet, y palabras añadidas manualmente). Así, por cada palabra candidata, se realiza una búsqueda de documentos en el índice generado en Lucene, retornando el documento (categoría) con el cual la palabra candidata se encuentra más relacionado, siendo asociada a la categoría de contexto correspondiente. En caso de no encontrar documentos (categorías) que contengan la palabra candidata, se considera que la palabra no contiene información de contexto.

Cabe destacar que, para tener en cuenta posibles variaciones en las palabras, por ejemplo, forma singular vs. forma plural, errores de escritura del usuario, o cambios deliberados a las palabras (por ejemplo, repetir la última vocal de la palabra para dar mayor énfasis), Lucene da la posibilidad de lematizar las palabras antes de incorporarlas como términos de un documento. Esto implica que, en lugar de almacenar la palabra original en el documento, se almacena el lema o raíz de la palabra. De esta manera, al realizar posteriormente una búsqueda, el término de búsqueda también es lematizado. Así, por ejemplo, se puede realizar un *matching* entre la palabra “*son*” en la taxonomía, y la palabra “*sons*” como palabra candidata. En caso de no lematizar las palabras, este matching no se realizaría. De esta forma, se puede observar que al no lematizar, se pierde flexibilidad para encontrar palabras que podrían representar contexto, pero que no se han escrito de la manera exacta en que se encuentran en la taxonomía. Por otro lado, al lematizar, se podría establecer matching con palabras que no representen necesariamente contexto. Esto plantea la necesidad de contar con alguna medida de confianza en la anotación de contexto realizada, lo que discute en el siguiente capítulo.

Capítulo 5

Pre-filtrado basado en Confianza

En este capítulo, se presenta un algoritmo de pre-filtrado basado en un indicador de confianza en el proceso de anotación de contexto descrito en el capítulo anterior. Este algoritmo permite tener un mayor nivel de confianza en la información contextual que será utilizada posteriormente en el proceso de recomendación.

5.1. Indicador de Confianza

En este trabajo, se busca establecer un nivel de confianza en la información de contexto extraída y anotada automáticamente mediante el proceso de anotación basado en taxonomía descrito previamente. Dado que la estructura de la taxonomía de contexto ha sido cuidadosamente diseñada, y los valores incorporados han sido revisados manualmente, para efectos de esta tesis, se entenderá como confianza un valor o puntuación asignada a la anotación, que mida la relación entre la palabra candidata a contener un valor de contexto, y la palabra con la que se empareja en la taxonomía de contexto. Esta puntuación será generada mediante un Indicador de Confianza.

El Indicador de Confianza será asignado a cada anotación de contexto, de acuerdo a la relación entre palabras utilizadas en el proceso de matching. Para ello, se medirá cuán similares son los términos consultados, basándose en criterios de edición (Navarro, 2001). Para esto, existen diferentes algoritmos de Distancia de Edición, los que en general miden la cantidad de modificaciones que debe sufrir una de las palabras (origen) para transformarse en la otra (destino).

Con este propósito, se consideraron algoritmos creados para la comparación de palabras y que permiten comparar palabras con largos diferentes. Se descartaron otros algoritmos que están relacionadas con la comparación de secuencias de caracteres (para comparar secuencias de ADN), o que no cumplen con admitir palabras de distinto largo (ej: Distancia Hamming

(Navarro, 2001)). A continuación, se describen los algoritmos de Distancia de Edición considerados en este trabajo como posibles indicadores de confianza.

5.1.1. Levenshtein

Esta distancia representa la cantidad de inserciones, eliminaciones y sustituciones requeridas para cambiar la palabra a probar con la palabra original, incluyendo la comparación de palabras de distinto largo (Levenshtein, 1965a).

Matemáticamente, la distancia entre dos palabras a y b se describe con la expresión $Lev_{a,b}(|a|, |b|)$:

$$Lev_{a,b}(i, j) = \begin{cases} \max(i, j) & , \quad \text{si } \min(i, j) = 0 \\ \min \begin{cases} Lev_{a,b}(i-1, j) + 1 \\ Lev_{a,b}(i, j-1) + 1 \\ Lev_{a,b}(i-1, j-1) + 1_{(a_i \neq b_j)} \end{cases} & , \quad \text{sino} \end{cases} \quad (31)$$

Donde la expresión $1_{(a_i \neq b_j)}$ indica que se asigna el valor 1 en caso de cumplir la condición $a_i \neq b_j$, y 0 en caso contrario. Esta fórmula, busca la mínima cantidad de cambios para que la palabra a se convierta en la palabra b .

Por ejemplo, la distancia Levenshtein entre las palabras “ahora” y “hora” es 1, ya que se requiere eliminar la letra “a” del inicio de la palabra “ahora” para cambiar a la palabra “hora”.

5.1.2. Damerau-Levenshtein

Esta distancia considera la distancia de Levenshtein, incorporando la cantidad de transposiciones como una edición simple, es decir, que no se eliminan e insertan ciertas letras, sino que se cambian de lugar en una sola acción (Damerau, 1964).

La siguiente expresión $DL_{a,b}(|a|, |b|)$ representa el algoritmo de distancia Damerau-Levenshtein, que toma elementos del algoritmo Levenshtein:

$$DL_{a,b}(i, j) = \begin{cases} \max(i, j) & , \quad \text{si } \min(i, j) = 0 \\ \min \begin{cases} DL_{a,b}(i-1, j) + 1 \\ DL_{a,b}(i, j-1) + 1 \\ DL_{a,b}(i-1, j-1) + 1_{(a_i \neq b_j)} \\ DL_{a,b}(i-2, j-2) + 1 \end{cases} & , \quad \text{si } i, j > 1 \text{ y } a_i = b_{j-1} \text{ y } a_{i-1} = b_j \\ \min \begin{cases} DL_{a,b}(i-1, j) + 1 \\ DL_{a,b}(i, j-1) + 1 \\ DL_{a,b}(i-1, j-1) + 1_{(a_i \neq b_j)} \end{cases} & , \quad \text{sino} \end{cases} \quad (32)$$

En esta expresión, la condición ($i, j > 1$ y $a_i = b_{j-1}$ y $a_{i-1} = b_j$) captura el caso de transposición de letras. Esta fórmula, sigue buscando la mínima cantidad de cambios para que la palabra a se convierta en la palabra b .

Por ejemplo, la distancia Levenshtein entre las palabras “ohra” y “hora” es 2, ya que elimina la letra “o” inicial y luego inserta una letra “o” en la segunda posición, es decir, dos acciones. Sin embargo, la distancia Damerau-Levenshtein entre las palabras “ohra” y “hora” es 1, ya que se realiza la transposición simple de las letras “oh” a “ho”, es decir, una acción.

5.1.3. Jaro-Winkler

Esta distancia responde con un valor decimal entre $[0,1]$, donde 0 representa que las palabras comparadas son completamente disimiles, mientras que el valor 1 representa palabras idénticas (Jaro, 1989; Winkler, 1990). Su criterio de comparación considera el largo de las palabras, la cantidad de caracteres que coinciden, el número de transposiciones y un valor ad-hoc que recompensa a cada letra que coincide desde el principio de la palabra.

Este algoritmo se compone de la fórmula de Jaro (Jaro, 1989), que consideran el largo de cada palabra $|a|$ y $|b|$, la cantidad de palabras coincidentes m , y el valor t que representa a la mitad de las transposiciones en la palabra, estos valores calculados con anterioridad.

$$J_{a,b} = \begin{cases} 0 & , \quad \text{si } m = 0 \\ \frac{1}{3} \left(\frac{m}{|a|} + \frac{m}{|b|} + \frac{m-t}{m} \right) & , \quad \text{sino} \end{cases} \quad (33)$$

La fórmula planteada por Winkler (Winkler, 1990), considera la fórmula de Jaro en ((32)), incluyendo los valores largo de prefijo l , y un valor constante p de compensación que no puede superar el valor 0.25, por lo general, se usa el valor 0.1. De esta manera, la fórmula recompensa las palabras que coinciden desde un principio a través de la siguiente expresión:

$$W_{a,b} = J_{a,b} + (lp(1 - J_{a,b})) \quad (34)$$

Finalmente, la fórmula de Jaro-Winkler es normalizado y se describe de la siguiente manera:

$$JW_{a,b} = 1 - W_{a,b} \quad (35)$$

Por ejemplo, la distancia Jaro-Winkler entre las palabras “ohra” y “hora” es 0.916; debido a que tienen la misma cantidad de letras y solamente es necesaria una transposición. Mientras que la distancia Jaro-Winkler entre las palabras “ahora” y “hora” es 0.933; ya que existe la letra “a” que eliminar para llegar a ser igual a la palabra “hora”.

5.2. Indicador de Confianza basado en Algoritmos de Distancia de Edición

Para calcular el indicador de confianza se realiza una normalización de los valores entregados por la distancia de edición a un valor entre [0,1] donde 0 representa que las palabras son completamente disimiles, y 1 que representa que las palabras son idénticas. Esta normalización toma en cuenta el valor de distancia junto con la longitud de las palabras, de la siguiente forma:

$$IC(w_1, w_2) = \frac{L - 2 \times D}{L} \tag{36}$$

donde D representa la distancia de edición entre las palabras w_1 y w_2 , y L se calcula como $\min(\text{length}(w_1), \text{length}(w_2))$.

En este procedimiento, se excluye el valor resultante del algoritmo Jaro-Winkler, debido a que ya entrega un valor normalizado.

A continuación, se muestra en sencillo ejemplo del funcionamiento de estos algoritmos como indicador de confianza. En la Figura 11 (a) se presenta una review real publicada por Tripadvisor, donde se resalta la palabra “huspend”. Por otro lado, en la Figura 11 (b) se muestra un extracto de la Taxonomía de Información Contextual, donde se resalta el término “Husband”.

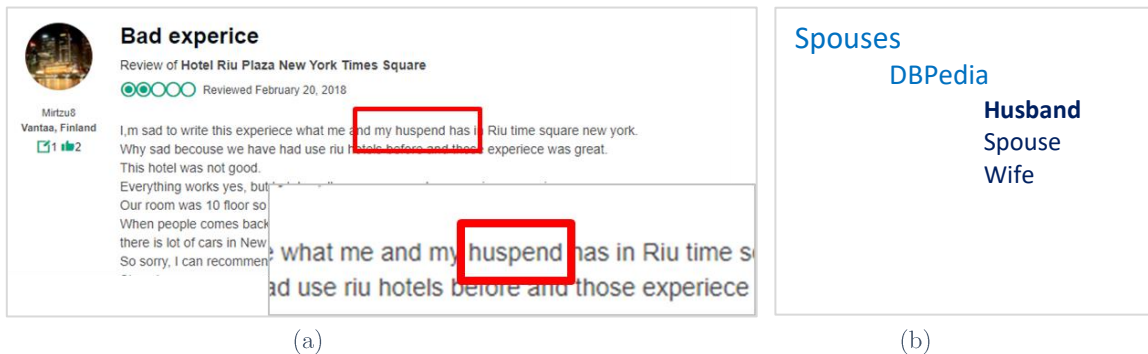


Figura 11: Ejemplo de Nivel de Similitud entre término de Review y término de Taxonomía (a) Ejemplo de Review en Tripadvisor, (b) Rama Spouses - Extracto de Taxonomía de Contexto

Para obtener el valor de indicador de confianza se aplica un algoritmo de distancia, para efectos del ejemplo se comparan los tres algoritmos de distancia expuestos. Los resultados son:

Algoritmo de Distancia	Distancia de Edición	Indicador de Confianza
levenshtein_distance(“huspend”, “husband”)	2	0.4285
damerau_levenshtein_distance(“huspend”, “husband”)	2	0.4285

jaro_winkler(“huspend”, “husband”)	-	0.8667
------------------------------------	---	--------

Tabla 4: Resultados de algoritmos de distancia de edición

En la Tabla 4, se puede apreciar la diferencia entre los resultados de los algoritmos de distancia. Cabe destacar que, el valor obtenido en el algoritmo Jaro-Winkler es debido al valor de compensación que se asigna al coincidir en las letras iniciales de las palabras comparadas.

Así, se puede apreciar que el uso de diferentes algoritmos de distancia de edición da lugar a diferentes valores de indicador de confianza. En el capítulo 7, se presentan experimentos sobre el comportamiento de estos diferentes algoritmos en los resultados de recomendación sobre diferentes algoritmos. Previo a esto, se describe el algoritmo de pre-filtrado basado en confianza diseñado.

5.3. Algoritmo de Pre-filtrado basado en Confianza

Utilizando el indicador de confianza presentado, se define un algoritmo de pre-filtrado basado en confianza, que considera un umbral de tolerancia (threshold), que es un valor ad-hoc que define el límite de confianza para considerar fiable una anotación de contexto.

Este algoritmo realiza un filtro de la información contextual que será considerada en el proceso de recomendación. Por ejemplo, si una anotación A tiene un valor de indicador de confianza de 0.84 y una anotación B tiene un valor de 0.43, con un valor de threshold de 0.5, la anotación A será usada en el proceso de recomendación, mientras que la anotación B no.

Gracias a que se utiliza como pre-filtrado, una vez aplicado, es posible utilizar cualquier algoritmo de predicción de recomendaciones conscientes del contexto, ya que selecciona la información de contexto antes de su uso por parte de los algoritmos.

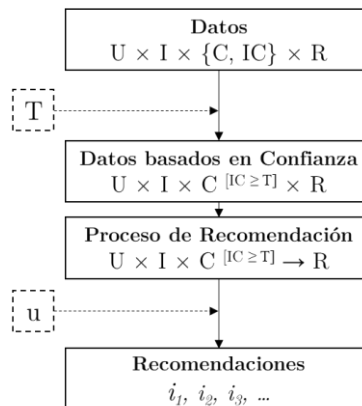


Figura 12: Representación de Algoritmo de Pre-filtrado basado en Indicador de Confianza

En la Figura 12 se muestra las acciones realizadas en el algoritmo de pre-filtrado basado en indicador de confianza, donde U representa el conjunto usuarios, el símbolo I representa el conjunto de ítems disponibles, la expresión $\{C, IC\}$ representan el conjunto de Contextos asociados a su indicador de confianza, y R representa el conjunto de ratings.

Esta información se puede representar mediante la función de recomendación contextual:

$$F: U \times I \times \{C \times IC\} \rightarrow R \quad (37)$$

En la ecuación (37), se expresa que la función de predicción se aplica sobre los conjuntos U (usuarios), I (ítems), C (contexto), IC (indicador de confianza), a partir de los cuales se genera una predicción de rating. El uso del pre-filtrado se puede representar de la siguiente forma (ver ecuación (38)):

$$F: U \times I \times C^{[IC \geq T]} \rightarrow R \quad (38)$$

La ecuación (38) muestra que sólo se utilizará la información de contexto cuyo índice de confianza (IC) sea mayor al threshold (T) definido, de manera similar a lo indicado en el cuadro “Datos basados en Confianza” de la Figura 12. Este procedimiento de pre-filtrado se especifica en el Algoritmo 1.

Algoritmo 1: Pre-Filtrado Basado en Confianza

Entrada: Un conjunto de contextos C y sus correspondientes indicadores de confianza IC , y un valor de threshold T .

Salida: Un conjunto de contextos C cuyo indicador de confianza es mayor o igual al threshold T

1. Por cada $c \in C$
 2. Si $IC_c \geq T$, (donde IC_c corresponde al valor de contexto c), Entonces
 3. Añadir c to $C^{[IC \geq T]}$
 4. **Retornar** $C^{[IC \geq T]}$
-

Usando el Algoritmo 1 con un valor de threshold $T=0.5$, sobre el valor obtenido con la distancia Jaro-Winkler en el ejemplo mostrado en la Tabla 4, el término “huspend” está asociado a la categoría “Spouses” a través de la instancia “husband”, y sobrepasa el valor de threshold impuesto, por lo que se incluye en el conjunto de información de contexto $C^{[IC \geq T]}$ para ser usado en el procedimiento de recomendación. Por el contrario, en caso de utilizar la distancia de Levenshtein o Damerau-Levenshtein, se descartaría dicha anotación contextual.

5.4. Complejidad computacional (análisis respecto a tiempo)

La complejidad computacional considera el procedimiento del cálculo de indicador de confianza y el algoritmo de pre-filtrado basado en confianza con respecto a su rendimiento en orden de tiempo. Para ello, es necesario conocer la forma en que funcionan estos procedimientos y en qué momento se ejecutan cada una de ellas.

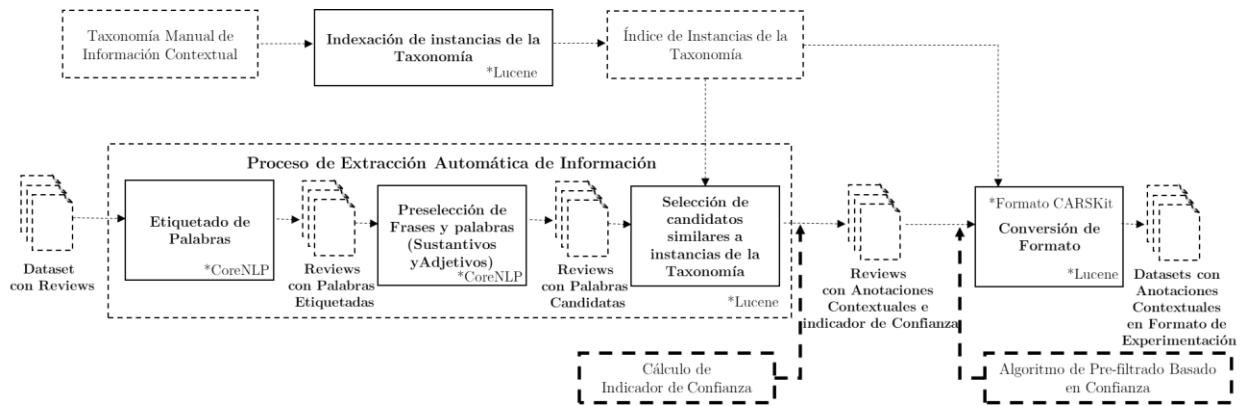


Figura 13: Proceso de Extracción automática de información

En la *Figura 13*, se presenta el proceso de extracción automática de información, donde se muestra que la interacción de los procedimientos antes mencionados se realizan de forma secuencial, por lo tanto, la complejidad total es la suma de la complejidad de cada procedimiento por separado.

Para el cálculo de indicador de confianza se consideran que cada palabra candidata se compare con cada instancia de la taxonomía. Esta comparación se efectúa mediante un algoritmo de distancia de edición, y finalmente se escoge el mejor resultado (ordenamiento descendente). Por lo tanto, la complejidad en tiempo es $O(N * M * (l_n * l_m) * \log M)$, donde N es la cantidad de palabras candidatas del dataset, M es la cantidad de instancias en la taxonomía, y los términos l_n y l_m son la cantidad de caracteres para los términos $n \in N$ y $m \in M$ respectivamente; en cuanto a la expresión $(l_n * l_m)$, corresponde a la complejidad de realizar una comparación con los algoritmos de distancia de edición (Damerau, 1964; Jaro, 1989; Levenshtein, 1965b; Winkler, 1990), mientras que la expresión $\log M$ corresponde al ordenamiento descendente con el fin de obtener el mejor valor de confianza.

Para el algoritmo de pre-filtrado basado en confianza analiza cada una de las palabras candidatas en el dataset, y selecciona aquellas que sobrepasan el valor de threshold establecido. Por lo tanto, la complejidad de este paso es de $O(N)$, ya que no consulta nuevamente los candidatos.

Finalmente, la complejidad total de los procedimientos efectuados para conseguir un pre-filtrado basado en indicador de confianza es $O(N * M * (l_n * l_m) * \log M) + O(N)$.

Capítulo 6

Diseño de Experimentos

En este capítulo se presenta el proceso de experimentación llevado a cabo. Se detallan la planificación de la experimentación, donde se describen los datasets usados en la experimentación, los algoritmos de recomendación, la metodología de evaluación y el uso de la librería especializada CARSKit en la ejecución de los experimentos.

6.1. Planificación de la Experimentación

En este apartado se explica todo el proceso de experimentación realizado en la investigación, que comprueban las contribuciones de este trabajo y permiten realizar un análisis de su comportamiento.

El proceso de experimentación tiene por objetivo comparar el impacto del uso de la información de contexto obtenida en base a la taxonomía desarrollada, considerando distintos umbrales de tolerancia de Confianza en la información contextual extraída, sobre distintos algoritmos de recomendación tradicionales y conscientes del contexto.

Es decir, que se han realizado pruebas sobre la calidad de la información extraída automáticamente, comprobando la efectividad de la taxonomía de información contextual desarrollada. Además, se comprueba el impacto de usar distintos niveles de indicador de

confianza, usando el algoritmo de pre-filtrado basado en confianza a través de la obtención de las métricas de evaluación para sistemas de recomendación.

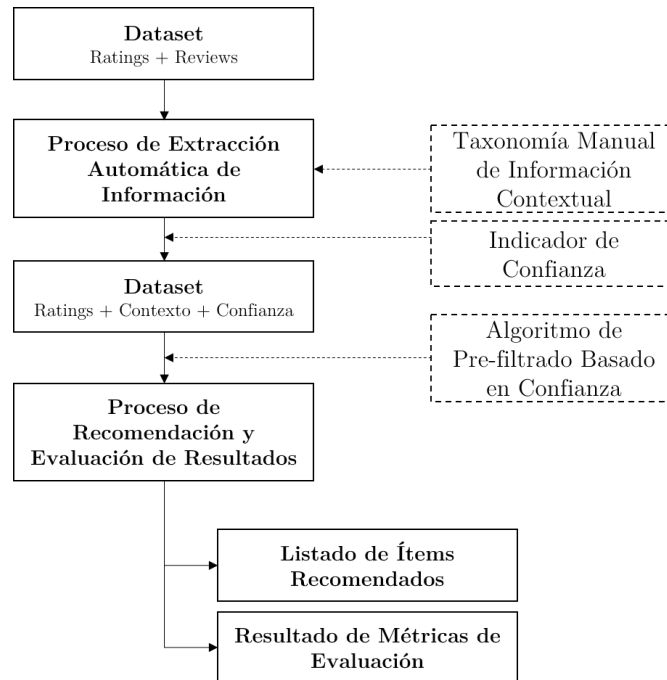


Figura 14: Proceso de Experimentación

En la Figura 14, se muestra visualmente los puntos en donde los aportes de este trabajo inciden en el proceso de recomendación. Por una parte, la taxonomía manual de información contextual es usada en la extracción automática de información, ya que se usa como base para la comparación de los términos candidatos a ser contexto con las categorías e instancias de la taxonomía. Por otra parte, se calcula el indicador de confianza asociado a cada anotación de contexto, añadiendo esta información al dataset anotado contextualmente. Mientras que el algoritmo de pre-filtrado basado en confianza opera sobre cada anotación de contexto y su respectivo indicador de confianza, donde se establece un valor threshold para filtrar la confianza que alcanza o supera dicho valor.

Luego de este proceso, se utilizan diferentes algoritmos de recomendación y se recolectan y presentan los resultados de las métricas de evaluación, donde se evidencia el comportamiento de los algoritmos de recomendación con respecto a la información contextual utilizada en las predicciones de ratings.

En adelante, se describen los dataset a usar y la metodología de evaluación, que describe los algoritmos de recomendación usados y las métricas de evaluación consideradas.

6.1.1. Descripción de Datasets

Para llevar a cabo los experimentos, se han utilizado datos de reviews publicados por la compañía Yelp¹⁴, que es una plataforma que califica la experiencia de los usuarios en distintos lugares de ocio y entretenimiento, tales como restaurantes, hoteles, tiendas, locales nocturnos, y en otros servicios; en particular, para este apartado de experimentación, se han empleado los datasets de Hotels y Beauty Spas (hoteles y spas de belleza).

	Dataset Yelp Beauty Spas	Dataset Yelp Hotels
Número de Usuarios	4272	4148
Número de Ítems	764	284
Número de Reviews	5579	5034

Tabla 5: Números de Usuarios, Ítems y Reviews por cada Dataset usado en la Experimentación

Estos datasets están en formato JSON (JavaScript Object Notation)¹⁵, que es un formato de intercambio de datos de baja carga, de simple lectura y escritura para las personas. En este formato se utilizan etiquetas para identificar cada elemento de un objeto, es decir, una review de usuario. En el siguiente cuadro de texto, se presenta una review recuperada desde el dataset Beauty Spas.

```
{
  "reviewerID": "K_ZAORjuL80YUhV1HC4PGQ",
  "asin": "ky3kuTeqTUOU4CsZ_2_LzQ",
  "summary": "summary",
  "reviewText": "My wife and I have stayed in many hotels both domestic and
international. From cheap hotels to very expensive resorts. For the price this hotel
was a great deal. Very clean and friendly staff. Very close to the airport and
provides FREE shuttle to/from airport.",
  "overall": 4.0
}
```

De esta manera, la etiqueta "reviewerID" representa el identificador de un usuario que realiza la review, la etiqueta "asin" representa al ítem que ha sido calificado, la etiqueta "reviewText" representa el comentario escrito por el usuario sobre el ítem, y la etiqueta "overall" representa la calificación (rating) que otorga el usuario al ítem. Para el caso de estos datasets, el rating está en una escala de cinco puntos, siendo el valor 1 el más bajo y el valor 5 el más alto.

¹⁴ Dataset disponible en: <https://www.yelp.com/dataset>

¹⁵ Información relacionada disponible en: <https://www.json.org/>

Para llevar a cabo la experimentación, en primer lugar cada uno de estos datasets se somete al procedimiento de extracción automática de información y cálculo de indicador de confianza.

El resultado de estos procedimientos es un dataset anotado contextualmente que contiene cada una de sus review, detallando usuario, ítem, rating, y anotaciones de contexto, junto con un indicador de confianza. A estas reviews que poseen información de contexto se les indican como “reviews con anotaciones”. En el siguiente, cuadro de texto se muestra la review del cuadro anterior en el formato con anotaciones.

```
K_ZAORjuL80YUhV1HC4PGQ ky3kuTeqTUOU4CsZ_2_LzQ 4.0 1000 Spouses%%wife%%2%%1.0
```

Posteriormente, se aplica el algoritmo de pre-filtrado basado en el indicador de confianza, con el cual se selecciona la información de contexto que sea sobre un valor umbral (threshold). En este proceso de experimentación se han considerado dos conjuntos de valores umbral de indicador de confianza; en una primera etapa de experimentación, se utiliza el valor de match exacto [1.0], para evaluar la efectividad de la taxonomía propuesta. En una segunda etapa, se utiliza el rango de valores [0.5, 0.6, 0.7, 0.8, 0.9, 1.0], para evaluar el impacto del pre-filtrado basado en confianza.

Con la información filtrada, el dataset se transforma al formato requerido por la librería CARSSKit para la ejecución de los diferentes algoritmos. En el siguiente cuadro, se puede apreciar el formato utilizado por CARSSKit usando el ejemplo del cuadro anterior.

```
K_ZAORjuL80YUhV1HC4PGQ, ky3kuTeqTUOU4CsZ_2_LzQ, 4, Spouses
```

Para la ejecución de los algoritmos CARS, se deben seleccionar las variables de contexto a utilizar. Esto es necesario, pues si se incluyeran todas las variables incluidas en la taxonomía, el proceso de recomendación sería excesivamente complejo, ya que crearía modelos o separaciones por cada variable de contexto considerada en el proceso de recomendación. Este problema es aún peor si se consideran variables de contexto que son subcategorías de otras variables de contexto, donde es posible que los algoritmos no sean capaces de encontrar modelos o separaciones que soporten la redundancia de variables de contexto, y no logren entregar una

solución. Para evitar este problema, es preferible considerar cada variable por separado en la experimentación. En caso de querer cubrir toda la estructura de la taxonomía, es posible considerar las variables de contexto de mayor nivel, es decir, las dimensiones de contexto Personal, Social y Environmental; ya que estas dimensiones son independientes entre ellas y todos los valores de contexto están contenidas en ellas.

Para lo anterior, se crean variantes del dataset original con las variables (y valores) de contexto a considerar. Para este proceso de experimentación, se han considerado las categorías de contexto de primer, segundo y tercer nivel (ver Tabla 6). Adicionalmente, se usa la variante “All” para denotar el dataset que contempla todas las variantes especificadas en el Nivel 1.

Categorías de Contexto			
Nivel 1	Personal	Social	Environmental
Nivel 2	Emotions Mood	Interpersonal Relationship Pet	-
Nivel 3	Positive Emotions Negative Emotions Other Emotions	Family Friendship	-

Tabla 6: Categorías de contexto usadas en experimentación

De esta forma, se ha realizado una revisión considerando estas categorías de contexto. En el caso de la categoría Environmental, se desestimó considerar niveles inferiores debido a que esta categoría tiene una subcategoría solamente, a diferencia de las categorías Personal y Social. En el caso del Nivel 3, se escogieron las subcategorías que poseen más conceptos y más niveles de granularidad.

6.1.2. Metodología de experimentación

En esta experimentación, se utiliza la librería especializada CARSKit (Zheng, 2015), que es un motor de recomendación consciente del contexto (ver sección 2.1.3).

El tipo de experimentación realizado es *off-line*, que consiste en emplear conjuntos de datos de usuarios, ítems y sus ratings (adicionalmente, información de contexto) que hayan sido recogidos previamente, dividiendo los datos en conjuntos de entrenamiento y prueba. Los primeros son utilizados para generar las recomendaciones, y los segundos son utilizados para evaluar los resultados obtenidos. En particular, se utilizó validación cruzada de 5-folds. Esto

permite evaluar un gran número de algoritmos de recomendación con un coste bajo, debido a que se cuenta con datos reales almacenados en datasets.

En la evaluación se usan algoritmos de recomendación provistos en CARSKit, agrupados en algoritmos baselines y algoritmos contextuales. Los algoritmos baseline son aquellos algoritmos tradicionales de recomendación, mientras que los algoritmos contextuales son aquellos que utilizan la información de contexto para realizar sus recomendaciones.

En la siguiente tabla se presentan los algoritmos de recomendación (con sus combinaciones) usados como baseline y consciente del contexto:

Algoritmos de Recomendación	
Baseline	UserKNN
Algoritmos Tradicionales	ItemKNN
	BiasedMF
	CAMF_C
	CAMF_CI
	CAMF_CU
	CAMF_CUCI
	ItemSplitting-UserKNN
	ItemSplitting-ItemKNN
	ItemSplitting-BiasedMF
	UserSplitting-UserKNN
	UserSplitting-ItemKNN
	UserSplitting-BiasedMF
	UserItemSplitting-UserKNN
	UserItemSplitting-ItemKNN
	UserItemSplitting-BiasedMF

Tabla 7: Resumen de Algoritmos de Recomendación usados en la Experimentación

Para comparar estos algoritmos de recomendación, se usan métricas de evaluación (ver sección 2.1.6). En esta experimentación, se considerarán métricas de rating (o de error) y de ranking (o precisión), con las que se mide el impacto del uso de una taxonomía de información contextual repercute en la calidad de la predicción de ratings o en la calidad de la lista de ítems recomendados. En la siguiente tabla, se presentan en detalle todas las métricas contempladas en la experimentación:

Métricas de Evaluación	
Rating	Ranking
MAE	Pre@5, Pre@10
RMSE	Rec@5, Rec@10
	MAP
	NDCG
	AUC

Tabla 8: Métricas de evaluación de algoritmos de recomendación usadas en experimentación

Se realizan experimentos centrados en las categorías de contexto propuestas, para evidenciar el impacto de la taxonomía de contexto sobre distintas categorías, y luego, se realiza un experimento que evidencia el comportamiento de las métricas de evaluación considerando distintos niveles de indicador de confianza.

En el primer experimento para el impacto en categorías, los datasets serán sometidos a todos los algoritmos de recomendación presentados en la Tabla 7. Mientras que, en el experimento para el impacto del indicador de confianza, se seleccionan los algoritmos que tienen mejores resultados en el experimento anterior. Con el fin de obtener resultados confiables, sobre ambos experimentos, cada algoritmo de recomendación (baseline y consciente de contexto) se ejecuta en 10 repeticiones y luego se promedian los resultados, obteniendo una métrica más fiable.

Los resultados de estos experimentos se presentan en el Capítulo 7, donde se profundiza en el comportamiento, las causas, y las tendencias presentes para cada dataset.

Capítulo 7

Análisis de Resultados y Discusión

En este capítulo, se expone el análisis de los resultados obtenidos del proceso de experimentación, en dos etapas. En primer lugar, se analiza la utilidad de la taxonomía de contexto para obtener información contextual útil para los algoritmos de recomendación. En segundo lugar, se analiza la utilidad del pre-filtrado de información, utilizando indicadores de confianza basados en diferentes distancias de edición y valores umbral. Para evaluar su utilidad, se comparan los resultados obtenidos al aplicar diferentes algoritmos de recomendación contextual.

Como ya se ha mencionado en el capítulo anterior, primeramente, se han ejecutado los algoritmos *baseline* para cada uno de los datasets, debido a que no consideran la información de contexto. A continuación, se presentan los resultados de las métricas de evaluación de algoritmos de recomendación *baseline*:

Métricas	Yelp Beauty Spas			Yelp Hotels		
	BiasedMF	ItemKNN	UserKNN	BiasedMF	ItemKNN	UserKNN
MAE	0.9763	1.0330	1.0330	0.9094	1.0157	1.0140
RMSE	1.2578	1.3275	1.3269	1.1503	1.2335	1.2288
Pre@5	0.0033	0.0034	0.0029	0.0117	0.0212	0.0203
Rec@5	0.0161	0.0164	0.0140	0.0576	0.1045	0.1001

Tabla 9: Métricas de evaluación de algoritmos Baseline sobre datasets Yelp Beauty Spas y Yelp Hotels

En estos resultados, se destacan los mejores valores respecto de sus métricas (usando letra **negrita**). En la Tabla 9, los mejores resultados para las métrica MAE y RMSE corresponden al algoritmo BiasedMF en ambos datasets, ya que son los valores más bajos respectivamente (es decir, con menor error); mientras que, los mejores resultados de Pre@5 y Rec@5 son entregados por el algoritmo ItemKNN en ambos datasets, debido a que son los valores más altos respectivamente.

Estos valores destacados son la base para comparar los resultados presentados en cada análisis. Por lo tanto, las contribuciones de este trabajo deben mejorar estos valores, con el fin de comprobar que llevan a mejoras en el rendimiento de los sistemas de recomendación.

7.1. Análisis de utilidad de la taxonomía de contexto

La influencia que ejerce la taxonomía de información de contexto en la obtención de información útil para sistemas de recomendación consciente de contexto se debe reflejar en las métricas de evaluación. Estas métricas evalúan si las predicciones de ratings son acertadas y la calidad de la lista de ítems recomendados.

Para este experimento se utilizó como variables de contexto categorías en diferentes niveles de la taxonomía propuesta (ver Tabla 6), además de la variable All que considera la categoría raíz de la taxonomía. Así también, se consideró que las palabras coincidieran totalmente o tener match exacto (valor threshold 1.0).

Con esta combinación, se pretende revisar el comportamiento de las métricas de rating y ranking por cada categoría de contexto utilizado en la experimentación.

7.1.1. Predicción de ratings

Este análisis consiste en comparar los resultados de las métricas de rating MAE y RMSE con cada categoría de contexto utilizada en la experimentación.

Ambas métricas miden el error de las predicciones, por lo tanto, el objetivo es disminuir los valores presentados en los algoritmos baseline. En la siguiente tabla, aquellos valores que sean mejores que el mejor valor presentado en los algoritmos baseline son resaltados con un color verde oscuro (■), mientras que aquellos valores obtenidos que sean mejores que su respectivo algoritmo baseline (en el caso de aproximaciones de tipo Splitting) son resaltados en verde claro (■), y el mejor valor por métrica es remarcado de los demás valores.

Yelp Beauty Spas														
	Variante	CAMF_	CAMF_	CAMF_	CAMF_	IS-	IS-	IS-	UIS-	UIS-	UIS-	US-	US-	US-
		C	CI	CU	CUCI	BiasedMF	ItemKNN	UserKNN	BiasedMF	ItemKNN	UserKNN	BiasedMF	ItemKNN	UserKNN
MAE	ALL	0.9443	0.9597	0.9571	0.9988	0.9792	1.0340	1.0333	0.9781	1.0341	1.0332	0.9761	1.0334	1.0329
	Emotions	0.9496	0.9827	0.9509	1.0240	0.9792	1.0337	1.0330	0.9787	1.0337	1.0331	0.9772	1.0330	1.0332
	Environmental	0.9716	0.9659	0.9533	1.0003	0.9767	1.0330	1.0330	0.9763	1.0330	1.0330	0.9753	1.0330	1.0330
	Family	0.9703	0.9789	0.9519	1.0105	0.9760	1.0333	1.0333	0.9768	1.0334	1.0332	0.9772	1.0331	1.0331
	Friendship	0.9750	0.9591	0.9470	0.9912	0.9775	1.0331	1.0333	0.9785	1.0331	1.0333	0.9771	1.0331	1.0329
	Interpersonal_Relationship	0.9737	0.9815	0.9519	1.0150	0.9775	1.0333	1.0333	0.9799	1.0335	1.0331	0.9772	1.0331	1.0327
	Mood	0.9757	0.9538	0.9486	0.9866	0.9774	1.0331	1.0332	0.9773	1.0331	1.0332	0.9776	1.0330	1.0330
	Negative_Emotions	0.9565	0.9691	0.9520	0.9948	0.9767	1.0324	1.0330	0.9759	1.0323	1.0330	0.9763	1.0330	1.0330
	Other_Emotions	0.9549	0.9670	0.9500	1.0074	0.9787	1.0338	1.0329	0.9783	1.0338	1.0329	0.9781	1.0330	1.0330
	Personal	0.9495	0.9835	0.9537	1.0258	0.9783	1.0337	1.0330	0.9779	1.0337	1.0331	0.9773	1.0330	1.0332
	Pet	0.9795	0.9516	0.9485	0.9857	0.9777	1.0332	1.0329	0.9766	1.0334	1.0328	0.9775	1.0334	1.0328
	Positive_Emotions	0.9746	0.9577	0.9501	1.0001	0.9792	1.0332	1.0329	0.9786	1.0336	1.0329	0.9770	1.0334	1.0329
	Social	0.9745	0.9838	0.9514	1.0151	0.9786	1.0333	1.0333	0.9781	1.0337	1.0330	0.9782	1.0335	1.0327
RMSE	ALL	1.2277	1.4269	1.4491	1.2902	1.2591	1.3280	1.3272	1.2590	1.3280	1.3272	1.2582	1.3277	1.3269
	Emotions	1.2313	1.3600	1.3055	1.2980	1.2593	1.3279	1.3269	1.2599	1.3279	1.3270	1.2591	1.3275	1.3270
	Environmental	1.2580	1.3186	1.3051	1.2800	1.2582	1.3275	1.3269	1.2572	1.3275	1.3269	1.2570	1.3275	1.3269
	Family	1.2515	1.3458	1.3063	1.2925	1.2579	1.3276	1.3271	1.2578	1.3277	1.3271	1.2586	1.3276	1.3269
	Friendship	1.2590	1.3049	1.2985	1.2691	1.2593	1.3275	1.3272	1.2600	1.3276	1.3272	1.2587	1.3276	1.3269
	Interpersonal_Relationship	1.2522	1.3552	1.3048	1.2972	1.2585	1.3277	1.3272	1.2603	1.3277	1.3271	1.2589	1.3276	1.3268
	Mood	1.2594	1.2935	1.3008	1.2628	1.2586	1.3275	1.3269	1.2589	1.3275	1.3269	1.2595	1.3275	1.3269
	Negative_Emotions	1.2386	1.3320	1.3043	1.2781	1.2586	1.3270	1.3269	1.2570	1.3270	1.3269	1.2580	1.3275	1.3269
	Other_Emotions	1.2431	1.3169	1.3030	1.2789	1.2593	1.3279	1.3269	1.2593	1.3279	1.3269	1.2597	1.3275	1.3269
	Personal	1.2294	1.3642	1.3071	1.3009	1.2591	1.3278	1.3269	1.2579	1.3278	1.3270	1.2583	1.3275	1.3270
	Pet	1.2608	1.2854	1.3005	1.2613	1.2584	1.3276	1.3269	1.2568	1.3277	1.3268	1.2589	1.3277	1.3268
	Positive_Emotions	1.2584	1.3019	1.3011	1.2709	1.2595	1.3276	1.3269	1.2588	1.3277	1.3269	1.2587	1.3276	1.3269
	Social	1.2535	1.3587	1.3069	1.2985	1.2583	1.3277	1.3272	1.2591	1.3278	1.3271	1.2599	1.3278	1.3268

Tabla 10: Métricas de Rating sobre dataset Yelp Beauty Spas

Yelp Hotels														
	Variante	CAMF_ C	CAMF_ CI	CAMF_ CU	CAMF_ CUCI	IS - BiasedMF	IS - ItemKNN	IS - UserKNN	UIS - BiasedMF	UIS - ItemKNN	UIS - UserKNN	US - BiasedMF	US - ItemKNN	US - UserKNN
MAE	ALL	0.8934	0.9862	1.0184	0.9210	0.9111	1.0172	1.0147	0.9105	1.0172	1.0147	0.9072	1.0157	1.0140
	Emotions	0.8961	0.9486	0.9348	0.9335	0.9090	1.0171	1.0148	0.9086	1.0171	1.0148	0.9089	1.0157	1.0140
	Environmental	0.9062	0.9411	0.9319	0.9305	0.9118	1.0167	1.0143	0.9079	1.0167	1.0143	0.9079	1.0157	1.0140
	Family	0.9105	0.9393	0.9328	0.9333	0.9098	1.0164	1.0142	0.9132	1.0164	1.0142	0.9094	1.0157	1.0140
	Friendship	0.9115	0.9277	0.9274	0.9195	0.9090	1.0166	1.0143	0.9068	1.0166	1.0143	0.9083	1.0157	1.0140
	Interpersonal_Relationship	0.9062	0.9475	0.9292	0.9365	0.9106	1.0164	1.0144	0.9096	1.0164	1.0144	0.9095	1.0157	1.0140
	Mood	0.9088	0.9308	0.9336	0.9206	0.9083	1.0159	1.0143	0.9094	1.0159	1.0143	0.9093	1.0157	1.0140
	Negative_Emotions	0.9049	0.9358	0.9285	0.9165	0.9072	1.0145	1.0138	0.9084	1.0145	1.0138	0.9089	1.0157	1.0140
	Other_Emotions	0.9036	0.9309	0.9330	0.9257	0.9094	1.0154	1.0143	0.9087	1.0154	1.0143	0.9085	1.0157	1.0140
	Personal	0.8960	0.9538	0.9319	0.9343	0.9079	1.0171	1.0148	0.9070	1.0171	1.0148	0.9096	1.0157	1.0140
	Pet	0.9121	0.9270	0.9319	0.9206	0.9089	1.0156	1.0140	0.9083	1.0156	1.0140	0.9071	1.0157	1.0140
	Positive_Emotions	0.9087	0.9324	0.9292	0.9252	0.9104	1.0158	1.0140	0.9103	1.0158	1.0140	0.9084	1.0157	1.0140
	Social	0.9081	0.9509	0.9322	0.9429	0.9108	1.0162	1.0141	0.9116	1.0162	1.0141	0.9071	1.0157	1.0140
RMSE	ALL	1.1352	1.3004	1.3507	1.1676	1.1502	1.2335	1.2292	1.1491	1.2335	1.2292	1.1481	1.2335	1.2288
	Emotions	1.1363	1.2326	1.1991	1.1731	1.1481	1.2335	1.2293	1.1482	1.2335	1.2293	1.1495	1.2335	1.2288
	Environmental	1.1464	1.2052	1.1983	1.1676	1.1528	1.2335	1.2290	1.1487	1.2335	1.2290	1.1487	1.2335	1.2288
	Family	1.1500	1.2117	1.1981	1.1726	1.1495	1.2341	1.2290	1.1534	1.2341	1.2290	1.1500	1.2335	1.2288
	Friendship	1.1471	1.1860	1.1934	1.1567	1.1498	1.2340	1.2290	1.1477	1.2340	1.2290	1.1489	1.2335	1.2288
	Interpersonal_Relationship	1.1476	1.2261	1.1944	1.1763	1.1505	1.2337	1.2291	1.1498	1.2337	1.2291	1.1499	1.2335	1.2288
	Mood	1.1447	1.1882	1.1999	1.1568	1.1497	1.2336	1.2290	1.1491	1.2336	1.2290	1.1496	1.2335	1.2288
	Negative_Emotions	1.1393	1.2070	1.1952	1.1557	1.1480	1.2312	1.2278	1.1497	1.2312	1.2278	1.1489	1.2335	1.2288
	Other_Emotions	1.1390	1.1945	1.1977	1.1621	1.1496	1.2332	1.2289	1.1494	1.2332	1.2289	1.1502	1.2335	1.2288
	Personal	1.1380	1.2391	1.1985	1.1730	1.1477	1.2335	1.2293	1.1460	1.2335	1.2293	1.1506	1.2335	1.2288
	Pet	1.1473	1.1827	1.1967	1.1564	1.1502	1.2335	1.2288	1.1486	1.2335	1.2288	1.1492	1.2335	1.2288
	Positive_Emotions	1.1465	1.2000	1.1963	1.1636	1.1505	1.2328	1.2288	1.1505	1.2328	1.2288	1.1494	1.2335	1.2288
	Social	1.1491	1.2322	1.1979	1.1821	1.1507	1.2332	1.2289	1.1510	1.2332	1.2289	1.1478	1.2335	1.2288

Tabla 11: Métricas de Rating sobre dataset Yelp Hotels

En la *Tabla 10*, que muestra los resultados para el dataset Yelp Beauty Spas, se puede apreciar que la mayoría de los valores obtenidos de la métrica MAE de los algoritmos CAMF están bajo el valor dado por el mejor valor MAE de los algoritmos baseline. En contraposición, solamente algunos de los valores de algoritmos tipo Splitting mejoran el valor de baseline. Esto se hace mucho más claro en la métrica RMSE, ya que solamente los valores obtenidos del algoritmo CAMF_C mejoran el valor baseline, mientras que muy pocos de los algoritmos tipo Splitting mejoran estos valores.

Por otro lado, el comportamiento de las métricas según categoría de contexto resulta aún más interesante, si bien todas las categorías de contexto representan una mejoría en alguno de los algoritmos, existen dos de ellas que resaltan por mejorar los resultados de MAE en cinco de los algoritmos: *Negative Emotions* y *Environmental*. Mientras que el mejor resultado lo obtiene la categoría **ALL** con un valor de **0.9442** en MAE (CAMF_C), resultado mejor que 0.9763 de BiasedMF; la categoría *ALL*, contiene todas las categorías, por lo que se puede intuir que al contemplar más información de contexto se obtienen mejores resultados en la predicción de ratings. Luego, las siguientes categorías con mejores resultados en MAE son *Personal* y *Emotions*.

Para la métrica RMSE, los resultados son similares a MAE, ya que se destacan las categorías: *Environmental*, *Family* y *Negative Emotions*. Además, el mejor resultado obtenido pertenece a la categoría **ALL** con un valor de **1.2277** (CAMF_C) que mejora el valor 1.2578 dado por BiasedMF; seguido de la categoría *ALL*, las categorías *Personal* y luego *Emotions* obtienen los mejores valores.

En el caso del dataset Yelp Hotels presentado en la *Tabla 11*, los resultados siguen mostrando una tendencia a mejorar los resultados en MAE y RMSE. Los algoritmos que mejores resultados obtuvieron fueron CAMF_C y todos los algoritmos de Splitting que usaron BiasedMF mejorando el resultado presentado en los algoritmos baseline. Sin embargo, el algoritmo que obtiene los mejores resultados es CAMF_C.

7.1.2. Ranking de ítems recomendados

Este análisis consiste en comparar los resultados de las métricas de rating Pre@5 y Rec@5 con cada categoría de contexto utilizado en la experimentación. Cabe recordar que, la métrica Pre@5 mide la proporción de los ítems recomendados relevantes respecto de los cinco primeros ítems recomendados, mientras que Rec@5 mide la proporción de los ítems recomendados relevantes respecto del total de ítems relevantes. Por lo tanto, mientras estos valores sean mayores, indicaría que hay una mayor proporción de ítems relevantes en la lista de recomendación, por ende, mejores recomendaciones.

Ambas métricas miden el ranking de recomendación, por lo tanto, el objetivo es aumentar los valores presentados en los algoritmos baseline. En la Tabla 12 y la Tabla 13, aquellos valores que sean mejores que el mejor valor presentado en los algoritmos baseline son resaltados con un color verde oscuro (■), mientras que aquellos valores obtenidos son mejores que su respectivo algoritmo baseline (aproximaciones Splitting) son resaltados en verde claro (■), y el mejor valor por métrica es remarcado de los demás valores.

En la Tabla 12, que representa los resultados de ranking del dataset Yelp Beauty Spas, se aprecia que los algoritmos que han tenido mejores resultados son los algoritmos CAMF_C, CAMF_CUCI, y los algoritmos de Splitting que incorporan ItemKNN y BiasedMF.

Considerando la métrica Pre@5, el mejor resultado es obtenido por el algoritmo ItemSplitting-ItemKNN con el valor **0.0040** que es mejor que el resultado baseline 0.0034 de ItemKNN. Cabe resaltar que, los resultados de los demás algoritmos son muy similares a este mejor valor de Pre@5.

Con respecto al comportamiento de las categorías de contexto en Pre@5, las siguientes categorías: *Environmental*, *Friendship*, *Mood*, *Negative Emotions*, *Other Emotions*, *Pet* y *Social*, presentan mejoras sobre al menos cinco algoritmos de recomendación contextual. Sin embargo, la categoría con el mejor resultado para Pre@5 es *Pet* con un valor de **0.0040** que es mejor que el resultado baseline 0.0034 de ItemKNN. Luego, los mejores resultados siguientes corresponden a: *Environmental*, *Friendship*, *Mood*, *Negative Emotions* y *Other Emotions*.

Para el caso de la métrica de Rec@5, las categorías que destacan son: *Environmental*, *Friendship*, *Other Emotions* y *Pet*, ya que mejoran los resultados en, al menos, cinco algoritmos de recomendación contextual. Sin embargo, el mejor resultado de Rec@5 lo obtiene el algoritmo CAMF_CUCI considerando la categoría *Interpersonal Relationship* con el valor de **0.0185** que es mejor que el resultado baseline 0.0164 de ItemKNN. Luego, los siguientes mejores resultados los obtuvieron las categorías de: *Friendship*, *Mood* y, después, *Emotions* y *Social*.

En este dataset se remarcan algunas características que se han destacado en la sección anterior. Una de estas características se destaca que las categorías de *Emotions* y sus subcategorías entregan información de contexto que repercute en la calidad de la lista de recomendación. Sin embargo, se destacan las categorías de *Interpersonal Relationship*, *Friendship* y *Social*, que tienen un impacto en cada métrica.

Yelp Beauty Spas														
	Variante	CAMF_ C	CAMF_ CI	CAMF_ CU	CAMF_ CUCI	IS - BiasedMF	IS - ItemKNN	IS - UserKNN	UIS - BiasedMF	UIS - ItemKNN	UIS - UserKNN	US - BiasedMF	US - ItemKNN	US - UserKNN
Pre@5	ALL	0.0031	0.0010	0.0010	0.0027	0.0028	0.0030	0.0026	0.0029	0.0029	0.0026	0.0033	0.0032	0.0028
	Emotions	0.0029	0.0013	0.0015	0.0035	0.0029	0.0032	0.0028	0.0029	0.0032	0.0028	0.0035	0.0035	0.0029
	Environmental	0.0037	0.0011	0.0015	0.0031	0.0035	0.0038	0.0032	0.0035	0.0038	0.0032	0.0036	0.0038	0.0032
	Family	0.0033	0.0012	0.0016	0.0036	0.0033	0.0031	0.0024	0.0033	0.0031	0.0024	0.0034	0.0037	0.0031
	Friendship	0.0039	0.0011	0.0016	0.0031	0.0034	0.0039	0.0031	0.0036	0.0039	0.0030	0.0034	0.0038	0.0030
	Interpersonal_Relationship	0.0036	0.0012	0.0015	0.0039	0.0034	0.0036	0.0029	0.0032	0.0035	0.0028	0.0032	0.0036	0.0029
	Mood	0.0038	0.0012	0.0016	0.0028	0.0035	0.0037	0.0031	0.0034	0.0037	0.0031	0.0035	0.0039	0.0032
	Negative_Emotions	0.0032	0.0013	0.0015	0.0031	0.0035	0.0035	0.0030	0.0033	0.0035	0.0030	0.0035	0.0038	0.0031
	Other_Emotions	0.0036	0.0012	0.0016	0.0031	0.0034	0.0037	0.0029	0.0033	0.0037	0.0029	0.0036	0.0037	0.0030
	Personal	0.0031	0.0013	0.0014	0.0036	0.0030	0.0032	0.0028	0.0029	0.0032	0.0028	0.0033	0.0035	0.0029
	Pet	0.0037	0.0011	0.0016	0.0028	0.0036	0.0040	0.0032	0.0036	0.0038	0.0032	0.0036	0.0038	0.0032
	Positive_Emotions	0.0035	0.0012	0.0014	0.0033	0.0031	0.0035	0.0030	0.0030	0.0035	0.0030	0.0035	0.0037	0.0030
	Social	0.0035	0.0011	0.0016	0.0036	0.0032	0.0035	0.0028	0.0032	0.0034	0.0028	0.0035	0.0034	0.0029
Rec@5	ALL	0.0151	0.0050	0.0050	0.0135	0.0136	0.0147	0.0129	0.0141	0.0142	0.0127	0.0164	0.0156	0.0136
	Emotions	0.0141	0.0065	0.0072	0.0174	0.0140	0.0152	0.0131	0.0143	0.0152	0.0131	0.0169	0.0166	0.0140
	Environmental	0.0171	0.0053	0.0073	0.0144	0.0166	0.0165	0.0143	0.0165	0.0165	0.0143	0.0168	0.0167	0.0143
	Family	0.0159	0.0057	0.0077	0.0171	0.0156	0.0143	0.0115	0.0155	0.0141	0.0116	0.0162	0.0164	0.0142
	Friendship	0.0179	0.0051	0.0074	0.0144	0.0160	0.0169	0.0141	0.0170	0.0167	0.0138	0.0162	0.0166	0.0138
	Interpersonal_Relationship	0.0175	0.0058	0.0074	0.0185	0.0160	0.0163	0.0136	0.0151	0.0160	0.0131	0.0156	0.0163	0.0135
	Mood	0.0178	0.0056	0.0073	0.0131	0.0161	0.0163	0.0140	0.0159	0.0163	0.0140	0.0163	0.0167	0.0143
	Negative_Emotions	0.0154	0.0060	0.0072	0.0151	0.0166	0.0156	0.0137	0.0154	0.0156	0.0137	0.0166	0.0167	0.0143
	Other_Emotions	0.0172	0.0057	0.0078	0.0148	0.0162	0.0165	0.0136	0.0158	0.0165	0.0136	0.0171	0.0166	0.0138
	Personal	0.0153	0.0061	0.0068	0.0174	0.0146	0.0149	0.0131	0.0143	0.0150	0.0131	0.0162	0.0166	0.0140
	Pet	0.0170	0.0051	0.0072	0.0128	0.0166	0.0166	0.0143	0.0165	0.0162	0.0144	0.0166	0.0162	0.0144
	Positive_Emotions	0.0169	0.0056	0.0068	0.0159	0.0146	0.0154	0.0139	0.0143	0.0155	0.0137	0.0166	0.0167	0.0140
	Social	0.0166	0.0055	0.0076	0.0175	0.0154	0.0162	0.0135	0.0151	0.0154	0.0131	0.0165	0.0158	0.0136

Tabla 12: Métricas de Ranking sobre dataset Yelp Beauty Spas

Yelp Hotels														
	Variante	CAMF_ C	CAMF_ CI	CAMF_ CU	CAMF_ CUCI	IS - BiasedMF	IS - ItemKNN	IS - UserKNN	UIS - BiasedMF	UIS - ItemKNN	UIS - UserKNN	US - BiasedMF	US - ItemKNN	US - UserKNN
Pre@5	ALL	0.0134	0.0018	0.0016	0.0111	0.0102	0.0188	0.0179	0.0104	0.0188	0.0179	0.0118	0.0212	0.0203
	Emotions	0.0128	0.0044	0.0072	0.0114	0.0108	0.0189	0.0182	0.0106	0.0189	0.0182	0.0119	0.0215	0.0205
	Environmental	0.0134	0.0043	0.0075	0.0102	0.0118	0.0213	0.0206	0.0124	0.0213	0.0206	0.0122	0.0216	0.0207
	Family	0.0133	0.0043	0.0079	0.0111	0.0113	0.0214	0.0201	0.0112	0.0214	0.0201	0.0122	0.0217	0.0207
	Friendship	0.0138	0.0048	0.0081	0.0106	0.0123	0.0220	0.0209	0.0121	0.0220	0.0209	0.0125	0.0220	0.0210
	Interpersonal_Relationship	0.0134	0.0045	0.0076	0.0115	0.0104	0.0216	0.0202	0.0110	0.0216	0.0202	0.0124	0.0216	0.0206
	Mood	0.0136	0.0040	0.0079	0.0102	0.0127	0.0219	0.0208	0.0125	0.0219	0.0208	0.0126	0.0220	0.0209
	Negative_Emotions	0.0136	0.0051	0.0075	0.0111	0.0101	0.0164	0.0154	0.0102	0.0164	0.0154	0.0121	0.0219	0.0208
	Other_Emotions	0.0122	0.0041	0.0080	0.0104	0.0115	0.0214	0.0202	0.0116	0.0214	0.0202	0.0124	0.0218	0.0208
	Personal	0.0125	0.0043	0.0077	0.0117	0.0109	0.0190	0.0182	0.0107	0.0190	0.0182	0.0122	0.0215	0.0205
	Pet	0.0137	0.0040	0.0079	0.0099	0.0128	0.0219	0.0210	0.0121	0.0219	0.0210	0.0124	0.0219	0.0210
	Positive_Emotions	0.0130	0.0043	0.0077	0.0112	0.0118	0.0216	0.0206	0.0118	0.0216	0.0206	0.0120	0.0217	0.0208
	Social	0.0132	0.0039	0.0076	0.0118	0.0112	0.0213	0.0201	0.0110	0.0213	0.0201	0.0121	0.0215	0.0205
Rec@5	ALL	0.0663	0.0089	0.0082	0.0550	0.0502	0.0926	0.0882	0.0512	0.0926	0.0882	0.0582	0.1045	0.1001
	Emotions	0.0625	0.0215	0.0352	0.0556	0.0525	0.0921	0.0889	0.0516	0.0921	0.0889	0.0580	0.1045	0.1004
	Environmental	0.0651	0.0205	0.0364	0.0493	0.0571	0.1033	0.0998	0.0600	0.1033	0.0998	0.0590	0.1044	0.1005
	Family	0.0643	0.0207	0.0383	0.0539	0.0544	0.1028	0.0976	0.0542	0.1028	0.0976	0.0588	0.1046	0.1007
	Friendship	0.0665	0.0233	0.0389	0.0509	0.0589	0.1046	0.1005	0.0582	0.1046	0.1005	0.0599	0.1046	0.1008
	Interpersonal_Relationship	0.0654	0.0220	0.0372	0.0563	0.0508	0.1041	0.0985	0.0534	0.1041	0.0985	0.0604	0.1045	0.1007
	Mood	0.0644	0.0192	0.0378	0.0487	0.0601	0.1042	0.0998	0.0594	0.1042	0.0998	0.0603	0.1046	0.1006
	Negative_Emotions	0.0651	0.0245	0.0360	0.0534	0.0486	0.0782	0.0747	0.0490	0.0782	0.0747	0.0580	0.1046	0.1006
	Other_Emotions	0.0588	0.0200	0.0385	0.0500	0.0556	0.1027	0.0978	0.0557	0.1027	0.0978	0.0595	0.1046	0.1005
	Personal	0.0611	0.0212	0.0378	0.0569	0.0528	0.0923	0.0891	0.0519	0.0923	0.0891	0.0595	0.1045	0.1004
	Pet	0.0653	0.0191	0.0377	0.0470	0.0608	0.1044	0.1007	0.0577	0.1044	0.1007	0.0592	0.1046	0.1006
	Positive_Emotions	0.0622	0.0205	0.0371	0.0537	0.0567	0.1037	0.0995	0.0568	0.1037	0.0995	0.0578	0.1045	0.1007
	Social	0.0647	0.0192	0.0369	0.0578	0.0550	0.1030	0.0984	0.0537	0.1030	0.0984	0.0593	0.1045	0.1005

Tabla 13: Métricas de Ranking sobre dataset Yelp Hotels

En la *Tabla 13*, que reúne los resultados de ranking para el dataset Yelp Hotels, existe una clara tendencia sobre los algoritmos de recomendación contextuales con mejores resultados, ya que solamente las aproximaciones de Splitting, específicamente, las aproximaciones de splitting que ocupan el algoritmo ItemKNN (en especial UserSplitting-ItemKNN) tienen resultados por sobre los valores de Pre@5 y Rec@5 correspondientemente.

En cuanto al impacto de las distintas categorías de contexto en Pre@5, las categorías: *Environmental*, *Family*, *Friendship*, *Interpersonal Relationship*, *Mood*, *Other Emotions*, *Pet*, *Positive Emotions* y *Social*, mejoran los resultados en tres de los algoritmos. Los mejores resultados de Pre@5 lo obtienen las categorías *Mood* y *Friendship*, con un valor de **0.0220** (UserSplitting-ItemKNN), que es mejor que el resultado baseline de 0.0212 (ItemKNN). Luego, las categorías que obtiene los siguientes resultados son: *Negative Emotions*, *Other Emotions* y *Pet*.

En el caso de Rec@5, la única categoría destacada es *Friendship*, ya que obtiene un valor de **0.1046** en los algoritmos Splitting con ItemKNN, que es mejor que el resultado baseline de 0.1045 (ItemKNN). Cabe destacar que todas las categorías, excepto *Environmental*, obtienen resultados sobre el valor baseline usando el algoritmo UserSplitting-ItemKNN.

Después de analizar ambos datasets, es posible evidenciar que los mejores resultados obtenidos de las métricas de ranking pertenecen a algoritmos Splitting, específicamente, esta tendencia se repite y es más marcada en el algoritmo UserSplitting-ItemKNN.

Respecto al comportamiento de las métricas de ranking según las distintas categorías de contexto, se repite la tendencia hacia la categoría *Emotions* y sus subcategorías, pero se incluyen las categorías de *Interpersonal Relationship* y sus subcategorías, en especial *Friendship*. A diferencia del análisis de la sección anterior, la categoría *ALL* no destacó sobre las demás, ya que sus resultados siempre estuvieron ligeramente por debajo del mejor valor de Pre@ y Rec@5.

Finalmente, se puede observar que usar una taxonomía de información contextual en el proceso de recomendación impacta positivamente en los resultados de las métricas de rating y ranking. Esto se debe a que la información de contexto permite personalizar aún más las predicciones y la lista de ítems a recomendar. Es notorio, que ciertas categorías de contexto, tienen mucho más impacto que otras en las métricas, por lo que se puede apreciar, las categorías relacionadas a las emociones del usuario (*Emotions*) y a la interacción del usuario con otras personas (*Interpersonal Relationship*), proveen contextos que caracterizan de mejor forma la situación del usuario. Por lo tanto, la estructura que presenta la taxonomía de información de contexto provee categorías que logran representar mejor la situación contextual que tiene el usuario y permiten mejorar la calidad de las recomendaciones realizadas, validando lo planteado en la hipótesis H1.

7.2. Análisis de utilidad de pre-filtrado basado en indicador de confianza

El objetivo de este análisis es evidenciar si aplicar un pre-filtrado sobre la información de contexto obtenida automáticamente impacta de forma positiva sobre las métricas de rating y ranking. Para esto, se analizan diferentes propuestas de indicadores de confianza y valores de threshold (umbral) de confianza.

En este experimento se consideran los siguientes valores de threshold [0.5, 0.6, 0.7, 0.8, 0.9, 1.0], con el fin de evidenciar el comportamiento de las métricas de evaluación en las categorías de contexto *Personal*, *Social*, *Environmental* y *ALL*. Además, se contempla utilizar los algoritmos de distancia de edición Levenshtein, Damerau-Levenshtein y Jaro-Winkler, para analizar su impacto en el cálculo del indicador de confianza en los resultados de las métricas de evaluación. Cabe notar que se utilizarán los algoritmos que han tenido mejor desempeño en la recomendación contextual (CAMF_C y UserSplitting-ItemKNN). Por lo tanto, se obtendrán resultados para cada métrica de evaluación sobre los datasets considerando los distintos niveles de indicador de confianza, cada algoritmo de distancia de edición y cada categoría de contexto, evaluados sobre dos algoritmos de recomendación contextual.

A continuación, se presenta la tabla de resultados para el dataset Yelp Beauty Spas, considerando ambos algoritmos de recomendación contextual sobre la categoría ALL (los resultados de todas las categorías se encuentran en 1.Anexo 1:). Para destacar los resultados se han destacado los mejores resultados por algoritmo de distancia y por métrica de evaluación mediante un color verde en degradé, por lo que las zonas más intensas (■) representan los mejores valores por métrica; y para destacar el mejor valor de cada métrica por algoritmo de recomendación se han remarcado las letras de aquellos resultados.

En la *Tabla 14*, se puede apreciar que los mejores resultados de las métricas de evaluación siguen la tendencia marcada en el análisis anterior, ya que los mejores resultados para las métricas de rating son obtenidos con el algoritmo CAMF_C, mientras que los mejores resultados para las métricas de ranking son obtenidas con el algoritmo UserSplitting-ItemKNN.

En la métrica MAE, el mejor resultado es 0.9347 (CAMF_C) que es mejor que el valor baseline 0.9763 (BiasedMF). Mientras que para RMSE, el mejor valor conseguido es 1.2136 (CAMF_C) que es mejor que el valor baseline 1.2578 (BiasedMF).

En cuanto a las métricas de ranking, el mejor valor para Pre@5 es 0.0034 (UserSplitting-ItemKNN) que es igual al valor baseline. Mientras que el valor de Rec@5 es 0.0168 (UserSplitting-ItemKNN) que es ligeramente mayor al valor baseline 0.0164 (ItemKNN).

Yelp Beauty Spas (ALL)	T	CAMF_C			UserSplitting-ItemKNN		
		Levenshtein	Damerau - Levenshtein	Jaro - Winkler	Levenshtein	Damerau - Levenshtein	Jaro - Winkler
MAE	0.5	0.9352	0.9347	0.9487	1.0332	1.0332	1.0330
	0.6	0.9448	0.9479	0.9481	1.0334	1.0334	1.0332
	0.7	0.9440	0.9452	0.9386	1.0335	1.0333	1.0330
	0.8	0.9400	0.9420	0.9442	1.0330	1.0334	1.0335
	0.9	0.9424	0.9435	0.9392	1.0332	1.0335	1.0331
	1.0	0.9443	0.9443	0.9443	1.0334	1.0334	1.0334
RMSE	0.5	1.2245	1.2232	1.2231	1.3276	1.3276	1.3275
	0.6	1.2259	1.2261	1.2216	1.3276	1.3276	1.3276
	0.7	1.2256	1.2306	1.2136	1.3277	1.3276	1.3275
	0.8	1.2250	1.2248	1.2189	1.3275	1.3277	1.3277
	0.9	1.2248	1.2229	1.2213	1.3276	1.3277	1.3276
	1.0	1.2277	1.2277	1.2277	1.3277	1.3277	1.3277
Pre@5	0.5	0.0029	0.0030	0.0029	0.0033	0.0033	0.0034
	0.6	0.0030	0.0031	0.0030	0.0034	0.0034	0.0033
	0.7	0.0030	0.0029	0.0032	0.0033	0.0033	0.0034
	0.8	0.0030	0.0029	0.0030	0.0034	0.0033	0.0033
	0.9	0.0030	0.0029	0.0031	0.0033	0.0033	0.0032
	1.0	0.0031	0.0031	0.0031	0.0032	0.0032	0.0032
Rec@5	0.5	0.0145	0.0150	0.0146	0.0160	0.0160	0.0168
	0.6	0.0149	0.0153	0.0147	0.0165	0.0165	0.0163
	0.7	0.0147	0.0142	0.0157	0.0161	0.0158	0.0165
	0.8	0.0147	0.0144	0.0150	0.0164	0.0160	0.0163
	0.9	0.0146	0.0143	0.0152	0.0160	0.0163	0.0157
	1.0	0.0151	0.0151	0.0151	0.0156	0.0156	0.0156

Tabla 14: Métricas sobre dataset Yelp Beauty Spas en distintos indicadores de confianza

A continuación, se presenta la tabla de resultados para el dataset Yelp Hotels, Al igual que la tabla anterior, se considera solamente la categoría ALL (ver 1.Anexo 1:). Para destacar los resultados se han destacado los mejores resultados por algoritmo de distancia y por métrica de evaluación mediante un color verde en degradé, por lo que las zonas más intensas (■) representan los mejores valores por métrica; y para destacar el mejor valor de cada métrica por algoritmo de recomendación se han remarcado las letras de aquellos resultados.

Yelp Hotels (ALL)	T	CAMF_C			UserSplitting-ItemKNN		
		Levenshtein	Damerau- Levenshtein	Jaro- Winkler	Levenshtein	Damerau- Levenshtein	Jaro- Winkler
MAE	0.5	0.9016	0.9053	0.8885	1.0157	1.0157	1.0157
	0.6	0.9047	0.8925	0.8934	1.0157	1.0157	1.0157
	0.7	0.9000	0.8916	0.8881	1.0157	1.0157	1.0157
	0.8	0.8976	0.8931	0.8893	1.0157	1.0157	1.0157
	0.9	0.9033	0.8934	0.8876	1.0157	1.0157	1.0153
	1.0	0.8934	0.8934	0.8934	1.0157	1.0157	1.0157
RMSE	0.5	1.1440	1.1459	1.1241	1.2335	1.2335	1.2331
	0.6	1.1461	1.1300	1.1292	1.2335	1.2335	1.2331
	0.7	1.1442	1.1306	1.1219	1.2335	1.2335	1.2331
	0.8	1.1412	1.1328	1.1237	1.2335	1.2335	1.2331
	0.9	1.1466	1.1314	1.1253	1.2335	1.2335	1.2329
	1.0	1.1352	1.1352	1.1352	1.2335	1.2335	1.2335
Pre@5	0.5	0.0141	0.0144	0.0131	0.0213	0.0213	0.0210
	0.6	0.0138	0.0138	0.0131	0.0213	0.0212	0.0210
	0.7	0.0146	0.0133	0.0137	0.0213	0.0212	0.0210
	0.8	0.0145	0.0134	0.0135	0.0213	0.0212	0.0210
	0.9	0.0143	0.0132	0.0135	0.0213	0.0212	0.0212
	1.0	0.0134	0.0134	0.0134	0.0212	0.0212	0.0212
Rec@5	0.5	0.0691	0.0707	0.0648	0.1044	0.1044	0.1041
	0.6	0.0676	0.0679	0.0652	0.1044	0.1044	0.1041
	0.7	0.0717	0.0655	0.0678	0.1044	0.1044	0.1041
	0.8	0.0712	0.0661	0.0670	0.1044	0.1045	0.1041
	0.9	0.0705	0.0653	0.0666	0.1044	0.1044	0.1047
	1.0	0.0663	0.0663	0.0663	0.1045	0.1045	0.1045

Tabla 15: Métricas sobre dataset Yelp hotels en distintos indicadores de confianza

En la Tabla 15, se puede apreciar que se sigue el mismo patrón que en la tabla anterior, ya que los mejores resultados para las métricas de rating son obtenidas con el algoritmo CAMF_C, mientras que los mejores resultados para las métricas de ranking son obtenidas con el algoritmo UserSplitting-ItemKNN.

En la métrica MAE, el mejor resultado es 0.8876 (CAMF_C) que es mejor que el valor baseline 0.9094 (BiasedMF). Mientras que, para la métrica RMSE se obtuvo un valor de 1.1219 (CAMF_C) que es mejor que el valor baseline 1.1503 (BiasedMF)

Por el lado de las métricas de rating, el mejor resultado dado en Pre@5 es 0.0213 (UserSplitting-ItemKNN) que es mejor que el valor baseline 0.0212 (ItemKNN). Mientras que,

en la métrica Rec@5 el mejor valor es 0.1047 (UserSplitting-ItemKNN) que es mejor que el valor baseline 0.1045 (ItemKNN).

A continuación, se analizan los resultados sobre dos criterios, el impacto de los algoritmos de distancia de edición, y el impacto del nivel de confianza en las métricas de evaluación.

7.2.1. Análisis sobre algoritmo de distancia de edición

Los algoritmos de distancia de edición tienen distintas formas de medir la similitud/diferencia al comparar términos (ver sección 5.1). Por ende, al considerar distintos niveles de confianza, estos algoritmos pueden resultar en variaciones de los resultados de las métricas de rating y ranking.

En la Tabla 14, los resultados de las métricas de evaluación muestran una cierta inclinación por el algoritmo Jaro-Winkler, ya que la mayor parte de los mejores resultados han sido obtenidos por este algoritmo; sin embargo, como indica la distribución del color, existen muchos valores que son muy similares, y varían ligeramente de estos mejores resultados. Por lo tanto, es un antecedente no concluyente, ya que no es completamente distinguible su impacto.

En la Tabla 15, se puede apreciar que no existe una tendencia con respecto a un algoritmo de distancia de edición, debido a que los valores son muy similares y, por lo tanto, los mejores resultados son compartidos por el algoritmo Levenshtein y Jaro-Winkler. Es por esto, que no se puede concluir que alguno de los algoritmos de distancia usados es mejor, ya que, por su definición, cada uno de ellos considera distintos tipos de variables en sus fórmulas.

Es por estas razones, no se puede determinar que utilizar un algoritmo de edición específico tenga un impacto directo en los resultados de las recomendaciones. Además, la complejidad de reconocer contexto desde fuentes textuales sobrepasa las capacidades de un algoritmo de distancia, debido a que existen otros problemas involucrados en la recuperación de información de tipo semántico, más relacionados con las técnicas de NLP, tales como detectar negaciones, polaridad, ironía, sentimiento y afecto.

7.2.2. Análisis sobre nivel de confianza

El nivel de confianza (o indicador de confianza), se ha definido como la medida normalizada de calidad de la información de contexto extraída desde fuentes textuales (ver sección 5.2). Entonces, si un contexto que es extraído desde una review tiene un indicador de confianza de 1.0, es porque corresponde exactamente con una instancia de la taxonomía de

información contextual; por lo que, si este valor varía desde 0 y es menor que 1, entonces la palabra recuperada no coincide del todo con el contexto dado en la taxonomía.

En la Tabla 14, que presentan los resultados para el dataset Yelp Beauty Spas, se aprecia que los mejores resultados de las métricas de evaluación se encuentran, por lo general, entre los niveles de threshold 0.5 a 0.7. Mientras que en la Tabla 15, que presenta los resultados para el dataset Yelp Hotels, el rango varía, estando los mejores resultados de las métricas entre los niveles 0.7 y 0.9 de Confianza.

En ambos casos, los mejores resultados no corresponden al valor 1.0 (coincidencia exacta), por lo que este patrón indica que los niveles inferiores a 1.0 reciben más información de contexto, y enriquecen más la información de ratings dada a los algoritmos de recomendación contextual y, por ende, reciben mejores resultados de las métricas de rating y de ranking.

Esto quiere decir, que imponer un valor de threshold alto, no asegura mejores resultados, debido a que al tolerar niveles menores de confianza es posible obtener contextos útiles al momento de realizar las recomendaciones. Sin embargo, se debe sacrificar un monto que algunas palabras se alejen demasiado de los contextos originales en la taxonomía. Además, el rango de la efectividad de confianza va a depender directamente del dataset, ya que el dominio y la interacción del usuario en las reviews pueden impactar en la calidad de la información obtenida, especialmente, debido a la complejidad de extraer información desde lenguaje natural.

Finalmente, se puede concluir que el nivel de confianza de la información tiene relación con la calidad de las predicciones y la lista de recomendación. Si bien no se aprecia una tendencia directa, es decir, a mayor nivel de confianza mejores resultados de las métricas de evaluación, se logra apreciar que existe un rango de niveles de confianza que generan los mejores resultados en los algoritmos de recomendación contextual. Considerando el comportamiento en ambos datasets, este rango tiene un nivel en común 0.7, y es posible este valor se considere un punto de inicio para la encontrar mejores resultados a través de un procedimiento de exploración, validando lo planteado en la hipótesis H2.

7.3. Discusión

En este análisis, se han detectado que las categorías *Emotions* e *Interpersonal Relationship* han sido constantemente destacadas. En ambos datasets, estas categorías han influido en los resultados y son las categorías que han recopilado prácticamente los mejores resultados para las métricas de evaluación.

Además de lo anterior, varios investigadores del área, entre ellos (Adomavicius & Tuzhilin, 2005b; Ricci, Rokach, & Shapira, 2015), argumentaban en sus trabajos que la

información de contexto está muy relacionada con el dominio de la aplicación, haciendo imposible replicar información de contexto de un dominio a otro. Sin embargo, en esta aproximación, la taxonomía reúne información de contexto que logra caracterizar la situación contextual del usuario en dos dominios distintos, lo que significa que esta taxonomía es una primera aproximación a una fuente válida y útil para cualquier dominio.

Siguiendo esta lógica, las categorías *Emotions* e *Interpersonal Relationship* adquieren mayor importancia, debido a que éstas pueden caracterizar la situación del usuario a un nivel más íntimo y particular. Una prueba de ello es que las emociones y la interacción con otras personas pueden modelar nuestros gustos y preferencias, tales como decidir visitar algún lugar turístico, ver alguna película, comprar ciertos artículos o comer en algún restaurante específico. Entonces, estas categorías son *transversales* o *multi-dominio* por naturaleza, ya que son características propias de los seres humanos.

Finalmente, estas categorías son una contribución asociada al desarrollo de una taxonomía de información de contexto, por lo que es necesario seguir la exploración de estas categorías e integrar otras tecnologías para potenciar los resultados obtenidos.

Capítulo 8

Conclusiones y Trabajos Futuros

En este capítulo se presentan las conclusiones obtenidas de esta investigación, describiendo los objetivos cumplidos, las contribuciones de la investigación y las líneas de trabajo futuro.

En este trabajo, se han alcanzado los objetivos planteados en el inicio de la investigación, y se han obtenido resultados interesantes sobre el comportamiento de algoritmos de recomendación conscientes del contexto sobre una taxonomía de información contextual.

El desarrollo de una taxonomía para anotaciones de información contextual, se ha realizado a través de la revisión de la literatura sobre el modelado de la información de contexto en sistemas ubicuos, pervasivos y de entorno inteligente. Donde se analizaron las aproximaciones, se describieron los tipos de modelado de información de contexto y las dimensiones de contexto contenidas en ellas. Luego, se desarrolló la taxonomía de información de contexto, tomando elementos de distintas aproximaciones, modificando categorías y creando estructuras nuevas para representar contexto. Este desarrollo de una estructura jerárquica responde al cumplimiento del objetivo específico 1.

Se ha desarrollado un algoritmo de pre-filtrado basado en confianza, que permite seleccionar la información de contexto obtenida automáticamente que resulta más fiable, a través de un indicador de confianza. Para ello se revisó la literatura sobre algoritmos de recomendación basados en confianza, y se definió el concepto de confianza en la información contextual. Este pre-filtrado ayuda a evaluar la información de contexto obtenida desde las reviews y explota el potencial de la taxonomía de información contextual. La implementación de este algoritmo satisface al objetivo 2 planteado.

Además, se ha realizado un procedimiento de experimentación y análisis sobre la calidad de las predicciones y la lista de recomendaciones. Para ello, se realizaron experimentos centrados en visualizar el comportamiento de categorías de contexto de la taxonomía sobre algoritmos de recomendación contextuales, y también, centrados en visualizar el comportamiento de distintos

niveles de confianza sobre dos algoritmos de recomendación contextual. Los resultados fueron analizados para detectar patrones y tendencias sobre el comportamiento en las categorías de contexto y en el nivel de confianza, con el fin de obtener los mejores resultados de las métricas de evaluación. Este procedimiento de experimentación y análisis, cumple con lo estipulado en el objetivo específico 3.

8.1. Contribuciones de la Investigación

Como ya se han descrito, las contribuciones en este trabajo se han desarrollado cumpliendo con los objetivos específicos planteados. En los siguientes puntos se expone el impacto de estas contribuciones en la investigación realizada:

- Realizar una revisión de la literatura sobre el modelado contextual ha permitido entender las técnicas de modelado de información de contexto, así como sus ventajas y desventajas. Se destaca, el potencial de los modelos basados en ontologías, debido a su poder de razonamiento. Así también, definir las dimensiones de contexto que se trabajan actualmente, y que tipo de información usan en sus aplicaciones contextuales.
- La revisión de la literatura es la base del desarrollo de una estructura jerárquica de contexto, es decir, la construcción de una taxonomía de información contextual. La implementación de esta taxonomía ha impactado directamente en los resultados obtenidos en los experimentos realizados.

De estos resultados se destaca, que las categorías de contexto impactan de diferente manera en las métricas de evaluación, mientras que es posible afirmar que considerar varias categorías de contexto (dimensiones) permite obtener mejores resultados para las métricas de evaluación.

- Definir un algoritmo de pre-filtrado basado en un indicador de confianza en la información de contexto extraída de forma automática, que permita obtener información de contexto con distintos valores de nivel de confianza, lo que implica obtener más información de contexto que pueda ser útil para recomendación.

Luego del proceso de experimentación y análisis, se puede evidenciar que existe un impacto en los resultados al considerar distintos niveles de confianza, evidenciando que se pueden obtener mejores resultados si se ocupa un nivel de confianza bajo el valor 1.0 (específicamente 0.7). Por lo que, se concluye que tolerar niveles de confianza lo suficientemente bajos (que no perjudiquen en la calidad de la información) permite obtener mejores resultados, debido a que se incluyen más información de contexto al dataset.

- Adicionalmente, se destacan las categorías *Emotions* e *Interpersonal Relationship*, por su impacto en los resultados de las métricas de evaluación. Estas dimensiones de

contexto resultan ser de importancia, ya que son capaces de caracterizar la situación contextual del usuario a un nivel más íntimo. De acuerdo a lo observado, estas categorías ayudan a producir mejores recomendaciones de forma transversal, es decir, independiente del dominio de la aplicación. De todas maneras, esto debe ser evaluado en otros datasets de diferentes dominios para obtener resultados más concluyentes.

De esta manera, se ha logrado mejorar la calidad tanto de las predicciones de rating y mejorado la calidad de la lista de recomendación. Se han resaltado algunas características importantes de la taxonomía de información contextual, tales como el nivel óptimo de confianza, y las categorías más relevantes. Finalmente, se proponen posibles líneas de investigación futuras.

8.2. Trabajo Futuro

Al realizar este trabajo, es posible identificar aproximaciones, tareas, o ideas que se pueden implementar con el fin de seguir la investigación, y mejorar los resultados obtenidos.

Los trabajos futuros propuestos se presentan sobre tres ejes: la extracción automática de información contextual, la creación de un algoritmo de recomendación contextual que incorpore la confianza en el cálculo de las predicciones, y profundizar la investigación sobre las categorías de más impacto para el usuario.

En cuanto al procedimiento de extracción automática de información contextual, existen algunas limitaciones que se plantearon al principio de la investigación. Estas limitaciones son parte de los problemas de NLP, y que corresponden a un análisis más semántico de las reviews, por ejemplo, polaridad, ironía, identificación de sentimientos y de afectos. Una línea de trabajo futura sería incorporar alguno de estos análisis específicos, con el fin de mejorar la extracción de información de contexto, eliminando casos de falsos positivos (ej: “esta película no es para verla con una mamá”, ya que reconoce “mamá” pero corresponde a un contexto en un sentido negativo), y añadiendo nuevos contextos (ej: “no me sentía bien y quise escuchar esta música”, podría reconocer un sentimiento de pena o angustia). Como ya se ha presentado en los análisis, con más información de contexto se obtienen mejores resultados.

Por otro lado, incorporar el valor del indicador de confianza es un algoritmo de recomendación contextual es un gran desafío. En el trabajo de (O’Donovan & Smyth, 2005b), se presenta una aproximación basada en modelado contextual, que incorpora el valor de confianza (Trust) en el cálculo de las predicciones usando como base un algoritmo de tipo User KNN. Otra aproximación, sería incorporarlo en un algoritmo de tipo CAMF, ya que estos ya incorporan el valor de contexto como factor para el cálculo de recomendaciones contextuales, siendo una opción homologar esta aproximación ocupando el valor de confianza. Los resultados

de las recomendaciones contextuales basadas en confianza debieran ser más fiables y personalizadas que las recomendaciones contextuales normales.

Por último, investigar sobre las categorías de más impacto para el usuario permitiría expandir el conocimiento sobre el concepto de contexto y sobre el impacto en las preferencias del usuario. En primera instancia, un trabajo futuro consistiría en evaluar todas las subcategorías de estas categorías más relevantes y comparar su impacto en las recomendaciones; para luego, buscar enriquecer aún más aquellas categorías con nuevas instancias. Por otro lado, se pueden explorar otras categorías (dimensiones) de contexto que pueden tener un igual o más relevancia para el usuario, así también, se puede investigar la incorporación de un indicador de relevancia de un contexto sobre un usuario, diferenciando aquellos contextos que tienen mayor impacto en los resultados de los algoritmos de recomendación contextual de aquellos que tienen un impacto mínimo sobre las métricas. Es posible, que se pueda establecer una escala de importancia de contexto con el cual apoyar el procedimiento de recomendación y obtener mejores resultados.

Para finalizar, cabe resaltar nuevamente el desarrollo de una taxonomía de información de contexto, que fue construida considerando técnicas de modelado de contexto obtenidas desde la revisión de la literatura, mejorando las recomendaciones a través de la incorporación de un indicador de confianza en la calidad de la información contextual. Es así, que esta aproximación permite obtener información de contexto de forma implícita usando las reviews, transformando datasets sin información contextual a datasets enriquecidos con información contextual y, de esta forma, proporcionando una solución parcial al problema de carencia de información contextual. Por lo que, además de generar mejores resultados en la predicción de rating y en el ranking de la lista de ítems a recomendar, se aporta en la solución de un problema profundo en el desarrollo de los sistemas de recomendación conscientes del contexto.

Referencias

- Abel, F. (2015). We Know Where You Should Work Next Summer: Job Recommendations. In *Proceedings of the 9th ACM Conference on Recommender Systems* (p. 230). New York, NY, USA: ACM.
- Aciar, S. (2010). Mining context information from consumers reviews. In *Proc. Workshop on Context-Aware Recommender Systems* (pp. 1–5).
- Adomavicius, G., Mobasher, B., Ricci, F., & Tuzhilin, A. (2011). Context-Aware Recommender Systems. *{AI} Magazine*, 32(3), 67–80.
- Adomavicius, G., Sankaranarayanan, R., Sen, S., & Tuzhilin, A. (2005). Incorporating Contextual Information in Recommender Systems Using a Multidimensional Approach. *ACM Trans. Inf. Syst.*, 23(1), 103–145.
- Adomavicius, G., & Tuzhilin, A. (2005a). Incorporating Context into Recommender Systems Using Multidimensional Rating Estimation Methods. In *Proceedings of the 1st International Workshop on Web Personalisation, Recommender Systems and Intelligent User Interfaces (ICETE 2005)* (pp. 3–13).
- Adomavicius, G., & Tuzhilin, A. (2005b). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. *IEEE Trans. on Knowl. and Data Eng.*, 17(6), 734–749.
- Amatriain, X. (2016). Past, Present, and Future of Recommender Systems: An Industry Perspective. In *Proceedings of the 21st International Conference on Intelligent User Interfaces* (p. 1). New York, NY, USA: ACM.
- Antunes, B., Cordeiro, J., & Gomes, P. (2012). SDiC: Context-based retrieval in eclipse. *Proceedings - International Conference on Software Engineering*, 1467–1468. <https://doi.org/10.1109/ICSE.2012.6227061>
- Balabanović, M., & Shoham, Y. (1997). Fab: Content-based, Collaborative Recommendation. *Commun. ACM*, 40(3), 66–72.
- Baltrunas, L., & Amatriain, X. (2009). Towards time-dependant recommendation based on implicit feedback. In *In Workshop on context-aware recommender systems (CARS 09)*.

- Baltrunas, L., Ludwig, B., & Ricci, F. (2011). Matrix Factorization Techniques for Context Aware Recommendation. In *Proceedings of the Fifth ACM Conference on Recommender Systems* (pp. 301–304). New York, NY, USA: ACM.
- Baltrunas, L., & Ricci, F. (2009). Context-based Splitting of Item Ratings in Collaborative Filtering. In *Proceedings of the Third ACM Conference on Recommender Systems* (pp. 245–248). New York, NY, USA: ACM.
- Bandara, K. Y., Wang, M., & Pahl, C. (2009). Context modeling and constraints binding in web service business processes. *Proceedings of the First International Workshop on Context-Aware Software Technology and Applications - CASTA '09*, 29. <https://doi.org/10.1145/1595768.1595780>
- Banko, M., Cafarella, M. J., Soderland, S., Broadhead, M., & Etzioni, O. (2007). Open Information Extraction from the Web. *IJCAI*, 7, 2670–2676.
- Bauman, K., & Tuzhilin, A. (2014). Discovering Contextual Information from User Reviews for Recommendation Purposes. In *Proc. Workshop on New Trends in Content-based Recommender Systems (CBRecSys2014)* (pp. 2–8). Silicon Valley, US: ACM Press.
- Bettini, C., Brdiczka, O., Henriksen, K., Indulska, J., Nicklas, D., Ranganathan, A., & Riboni, D. (2010). A survey of context modelling and reasoning techniques. *Pervasive and Mobile Computing*, 6(2), 161–180. <https://doi.org/10.1016/j.pmcj.2009.06.002>
- Bhargava, P., Krishnamoorthy, S., & Agrawala, A. (2012a). An ontological context model for representing a situation and the design of an intelligent context-aware middleware. *Proceedings of the 2012 ACM Conference on Ubiquitous Computing (UbiComp '12)*, 1016–1025. <https://doi.org/10.1145/2370216.2370436>
- Bhargava, P., Krishnamoorthy, S., & Agrawala, A. (2012b). RoCoMo: A Generic Ontology for Context Modeling, Representation and Reasoning in a Context-aware Middleware. *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*, 584–585. <https://doi.org/10.1145/2370216.2370316>
- Bhargava, P., Krishnamoorthy, S., & Agrawala, A. (2015). Modeling context and situations in pervasive computing environments. *ArXiv Preprint ArXiv:1503.07159*, 1–10.
- Biamino, G. (2011a). Modeling Social Contexts for Pervasive Computing Environments, 415–420.
- Biamino, G. (2011b). So Smart - Modeling social contexts to improve smart objects awareness in pervasive computing environments. *2011 IEEE International Conference on Pervasive Computing and Communications Workshops, PERCOM Workshops 2011*, 393–394. <https://doi.org/10.1109/PERCOMW.2011.5766916>
- Biamino, G., & Cena, F. (2011). Social awareness and user modeling to improve objects

- intelligence. *Proceedings - 2011 IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technology - Workshops, WI-IAT 2011*, 3, 118–121. <https://doi.org/10.1109/WI-IAT.2011.260>
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research*, 3(4–5), 993–1022.
- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender Systems Survey. *Know.-Based Syst.*, 46, 109–132.
- Bobillo, F., Delgado, M., & Gómez-Romero, J. (2008). Representation of context-dependant knowledge in ontologies: A model and an application. *Expert Systems with Applications*, 35(4), 1899–1908. <https://doi.org/10.1016/j.eswa.2007.08.090>
- Bradley, A. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145–1159. [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2)
- Brickley, D., & Miller, L. (2000). FOAF Vocabulary Specification 0.98. Retrieved from <http://xmlns.com/foaf/spec/>
- Burke, R. (2007). Hybrid Web Recommender Systems. *The Adaptive Web*, 377–408. https://doi.org/10.1007/978-3-540-72079-9_12
- Campos, P. G., Rodríguez-Artigot, N., & Cantador, I. (2017). Extracting Context data from user reviews for recommendation: A Linked Data approach. *A Linked Data Approach. In Proc. Workshop on Complex Recommendation (ComplexRec)*.
- Castelli, G., Castelli, G., Rosi, A., Rosi, A., Mamei, M., Mamei, M., ... Zambonelli, F. (2007). A Simple Model and Infrastructure for Context-Aware Browsing of the World. *Fifth Annual IEEE International Conference on Pervasive Computing and Communications (PerCom'07)*, 229–238. <https://doi.org/10.1109/PERCOM.2007.4>
- Chen, H., Finin, T., & Joshi, A. (2004). Semantic Web in the context broker architecture. In *Pervasive Computing and Communications, 2004. PerCom 2004. Proceedings of the Second IEEE Annual Conference on* (pp. 277–286).
- Chen, H., Perich, F., Finin, T., & Joshi, A. (2004). SOUPA: standard ontology for ubiquitous and pervasive applications. In *Mobile and Ubiquitous Systems: Networking and Services 2004. The First Annual International Conference on* (pp. 258–267).
- Christopoulou, E., Goumopoulos, C., & Kameas, A. (2005). An ontology-based context management and reasoning process for UbiComp applications. *Proceedings of the 2005 Joint Conference on Smart Objects and Ambient Intelligence: Innovative Context-Aware Services: Usages and Technologies*, (october), 5–10. <https://doi.org/http://doi.acm.org/10.1145/1107548.1107613>

- Codina, V., Ricci, F., & Ceccaroni, L. (2013). Local Context Modeling with Semantic Pre-filtering. In *Proceedings of the 7th ACM Conference on Recommender Systems* (pp. 363–366). New York, NY, USA: ACM. <https://doi.org/10.1145/2507157.2507218>
- Da, K., Roose, P., Dalmau, M., Nevado, J., & Karchoud, R. (2014). Kali2Much. *Proceedings of the 1st ACM Workshop on Middleware for Context-Aware Applications in the IoT - M4IOT '14*, 25–30. <https://doi.org/10.1145/2676743.2676748>
- Dai, P., & Xu, G. (2008). Context-aware computing for assistive meeting system. *Proceedings of the 1st ACM International Conference on Pervasive Technologies Related to Assistive Environments - PETRA '08*, 1. <https://doi.org/10.1145/1389586.1389591>
- Damerau, F. J. (1964). A Technique for Computer Detection and Correction of Spelling Errors. *Commun. ACM*, 7, 171–176.
- Dey, A. K. (2001). Understanding and using context. *Personal and Ubiquitous Computing*, 5(1), 4–7. <https://doi.org/10.1007/s007790170019>
- Dourish, P. (2004). What We Talk About when We Talk About Context. *Personal Ubiquitous Comput.*, 8(1), 19–30.
- Echtibi, A., Zemerly, M. J., & Berri, J. (2009). Murshid. *Proceedings of the 1st International Workshop on Context-Aware Middleware and Services Affiliated with the 4th International Conference on Communication System Software and Middleware (COMSWARE 2009) - CAMS '09*, (July), 6. <https://doi.org/10.1145/1554233.1554236>
- Ejigu, D., Scuturici, V.-M., & Brunie, L. (2007). An Ontology-Based Approach to Context Modeling and Reasoning in Pervasive Computing, 14–19. <https://doi.org/10.1109/PERCOMW.2007.22>
- Ekman, P. (1973). *Darwin and Facial Expression: A Century of Research in Review*. Academic Press. Retrieved from <https://books.google.cl/books?id=2JtpAAAAMAAJ>
- Gediminas Adomavicius, Bamshad Mobasher, Francesco Ricci, and A. T. (2011). Context-aware recommender systems. *Recommender Systems Handbook, Second Edition*, 191–226. https://doi.org/10.1007/978-1-4899-7637-6_6
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using Collaborative Filtering to Weave an Information Tapestry. *Commun. ACM*, 35(12), 61–70.
- Gomez-Uribe, C. A., & Hunt, N. (2015). The Netflix Recommender System: Algorithms, Business Value, and Innovation. *ACM Trans. Manage. Inf. Syst.*, 6(4).
- Gu, T., Wang, X. H., Pung, H. K., & Zhang, D. Q. (2004). An Ontology-based Context Model in Intelligent Environments. In *IN PROCEEDINGS OF COMMUNICATION NETWORKS AND DISTRIBUTED SYSTEMS MODELING AND SIMULATION*

CONFERENCE (pp. 270–275).

- Halpin, T. A. (2001). *Information modeling and relational databases: from conceptual analysis to logical design*. San Francisco: Morgan Kaufman Publishers.
- Heckmann, D., Schwartz, T., Brandherm, B., Schmitz, M., & von Wilamowitz-Moellendorff, M. (2005). Gumo -- The General User Model Ontology. In L. Ardissono, P. Brna, & A. Mitrovic (Eds.), *User Modeling 2005* (pp. 428–432). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Henricksen, K., & Indulska, J. (2006). Developing context-aware pervasive computing applications: Models and approach. *Pervasive and Mobile Computing*, 2(1), 37–64. <https://doi.org/10.1016/j.pmcj.2005.07.003>
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems (TOIS)*, 22(1), 5–53. <https://doi.org/10.1145/963770.963772>
- Hu, Y., Koren, Y., & Volinsky, C. (2008). Collaborative Filtering for Implicit Feedback. *IEEE International Conference on Data Mining*, 263–272. <https://doi.org/10.1109/ICDM.2008.22>
- HUMAINE Emotion Annotation and Representation Language. (n.d.). Retrieved June 25, 2018, from Emotion-research.net
- Indulska, J., Robinson, R., Rakotonirainy, A., & Henricksen, K. (2003). Experiences in Using CC/PP in Context-Aware Systems. In *In Proc. of the Intl. Conf. on Mobile Data Management (MDM)* (pp. 247–261). Springer.
- Jaro, M. A. (1989). Advances in Record-Linkage Methodology as Applied to Matching the 1985 Census of Tampa, Florida. *Journal of the American Statistical Association*, 84(406), 414–420. <https://doi.org/10.1080/01621459.1989.10478785>
- Jaroucheh, Z., Liu, X., & Smith, S. (2012). An approach to domain-based scalable context management architecture in pervasive environments. *Personal and Ubiquitous Computing*, 16(6), 741–755. <https://doi.org/10.1007/s00779-011-0422-0>
- Jayaraman, P. P., Zaslavsky, A., & Delsing, J. (2009). Dynamic situation modeling and reasoning under uncertainty. *Proceedings of the 2009 International Conference on Pervasive Services - ICPS '09*, 113. <https://doi.org/10.1145/1568199.1568217>
- Jones, S., & O'Neill, E. (2009). Context-aware messaging: how personal, spatial and temporal constraints affect text-based communication. *Proceedings of the 8th International Conference on Mobile and Ubiquitous Multimedia*, 8. <https://doi.org/10.1145/1658550.1658558>

- Kantor, P., Ricci, F., & Rokach, L. (2009). *Recommender systems handbook. Media*. Retrieved from <http://www.lavoisier.fr/livre/notice.asp?id=O2SWLSAASR6OWX>
- Karatzoglou, A., Amatriain, X., Baltrunas, L., & Oliver, N. (2010). Multiverse Recommendation: N-dimensional Tensor Factorization for Context-aware Collaborative Filtering. In *Proceedings of the Fourth ACM Conference on Recommender Systems* (pp. 79–86). New York, NY, USA: ACM.
- Ko, H.-G., Son, J.-S., & Ko, I.-Y. (2015). Multi-Aspect Collaborative Filtering Based on Linked Data for Personalized Recommendation. In *Proceedings of the 24th International Conference on World Wide Web*. New York, NY, USA: ACM.
- Koren, Y. (2008). Factorization Meets the Neighborhood: A Multifaceted Collaborative Filtering Model. In *Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 426–434). New York, NY, USA: ACM.
- Koren, Y. (2009). Collaborative filtering with temporal dynamics. *Knowledge Discovery and Data Mining {KDD}*, 447–456. <https://doi.org/10.1145/1557019.1557072>
- Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), 30–37. <https://doi.org/10.1109/MC.2009.263>
- Lee, D., & Meier, R. (2009). A hybrid approach to context modelling in large-scale pervasive computing environments. *Proceedings of the Fourth International ICST Conference on COMMunication System SoftWARE and MiddlewaRE - COMSWARE '09*, (December), 1. <https://doi.org/10.1145/1621890.1621909>
- Lenat, D. B. (1995). CYC: A Large-scale Investment in Knowledge Infrastructure. *Commun. ACM*, 38(11), 33–38. <https://doi.org/10.1145/219717.219745>
- Lenat, D. B., & Guha, R. V. (1989). *Building Large Knowledge-Based Systems; Representation and Inference in the Cyc Project* (1st ed.). Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc.
- Leskovec, J. (2015). New Directions in Recommender Systems. In *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining* (pp. 3–4). New York, NY, USA: ACM.
- Levenshtein, V. I. (1965a). Binary codes capable of correcting deletions, insertions, and reversals. *Soviet Physics Doklady*, 10(8), 707–710. <https://doi.org/citeulike-article-id:311174>
- Levenshtein, V. I. (1965b). Binary Codes Capable of Correcting Deletions, Insertions, and Reversals. *Soviet Physics Doklady*, 10, 707–710.
- Li, Y., Nie, J., Zhang, Y., Wang, B., Yan, B., & Weng, F. (2010). Contextual Recommendation

- based on Text Mining. *Coling 2010: Posters*, (August), 692–700. Retrieved from <http://www.aclweb.org/anthology/C10-2079>
- Lum, W. Y., & Lau, F. C. M. (2002). A Context-Aware Decision Engine for Content Adaptation. *IEEE Pervasive Computing*, 1(3), 41–49.
- Malek, J., Laroussi, M., & Derycke, A. (2008). ContAct-Us: a Context-Activity Adaptive Modeler for Ubiquitous Learning Systems. *Cstst 2008*, 530–535. <https://doi.org/10.1145/1456223.1456330>
- Manning, C., Surdeanu, M., Bauer, J., Finkel, J., Bethard, S., & McClosky, D. (2014). The Stanford CoreNLP Natural Language Processing Toolkit. *Proceedings of 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, 55–60. <https://doi.org/10.3115/v1/P14-5010>
- Massa, P., & Avesani, P. (2004). Trust-aware collaborative filtering for recommender systems. *Lecture Notes in Computer Science*, 3290, 492–508. https://doi.org/10.1007/978-3-540-30468-5_31
- Massa, P., & Avesani, P. (2007). Trust-aware recommender systems. *Proceedings of the 2007 ACM Conference on Recommender Systems RecSys 07*, 20, 17–24. <https://doi.org/10.1145/1297231.1297235>
- Meymandpour, R., & Davis, J. G. (2012). Recommendations Using Linked Data. In *Proceedings of the 5th Ph.D. Workshop on Information and Knowledge* (pp. 75–82). New York, NY, USA: ACM.
- Middleton, S. E., Shadbolt, N. R., & De Roure, D. C. (2004). Ontological User Profiling in Recommender Systems. *ACM Trans. Inf. Syst.*, 22(1), 54–88.
- Mihalcea, R., & Csomai, A. (2007). Wikify!: Linking Documents to Encyclopedic Knowledge. In *Proceedings of the Sixteenth ACM Conference on Conference on Information and Knowledge Management* (pp. 233–242). New York, NY, USA: ACM.
- Min, J. K., Kim, H. T., & Cho, S. B. (2008). Social and personal context modeling for contact list recommendation on mobile device. *Proceedings - 2008 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology - Workshops, WI-IAT Workshops 2008*, 381–384. <https://doi.org/10.1109/WIAT.2008.367>
- Mohammad, S. M., & Turney, P. D. (2010). Emotions evoked by common words and phrases: using mechanical turk to create an emotion lexicon. *CAAGET '10 Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text*, (June), 26–34. Retrieved from <http://dl.acm.org/citation.cfm?id=1860631.1860635>
- Moradi, P., & Ahmadian, S. (2015). A reliability-based recommendation method to improve

- trust-aware recommender systems. *Expert Systems with Applications*, 42(21), 7386–7398. <https://doi.org/10.1016/j.eswa.2015.05.027>
- Murdock, G. P. (1949). Social Structure, 387.
- Murphy, G. C., & Murphy-Hill, E. (2010). What is trust in a recommender for software development? *Proc. RSSE*, 57–58. <https://doi.org/10.1145/1808920.1808934>
- Nadeau, D., & Sekine, S. (2007). A survey of named entity recognition and classification. *Linguisticae Investigationes*, 30(1), 3–26.
- Najar, S., Saidani, O., Kirsch-Pinheiro, M., Souveyet, C., & Nurcan, S. (2009). Semantic Representation of Context Models: A Framework for Analyzing and Understanding. *Proceedings of the 1st Workshop on Context, Information and Ontologies*, (May), 1–10. <https://doi.org/10.1145/1552262.1552268>
- Nassar, L. N., Karray, F., Kamel, M., & Sattar, F. (2012). VANET IR-CAS: Utilizing IR Techniques in Developing Context Aware System for VANET. *Proceedings of the Second ACM International Symposium on Design and Analysis of Intelligent Vehicular Networks and Applications*, 97–104. <https://doi.org/10.1145/2386958.2386973>
- Navarro, G. (2001). A guided tour to approximate string matching. *ACM Computing Surveys*, 33(1), 31–88.
- Neto, R. F. B., Kudo, T. N., & da Graça Pimentel, M. (2006). Using a software process for ontology-based context-aware computing. *Proceedings of the 12th Brazilian Symposium on Multimedia and the Web - WebMedia '06*, 192(November 1922), 61. <https://doi.org/10.1145/1186595.1186604>
- O'Donovan, J., & Smyth, B. (2005a). Trust in recommender systems. *Proceedings of the 10th International Conference on Intelligent User Interfaces IUI 05*, 05pages(June), 167. <https://doi.org/10.1145/1040830.1040870>
- O'Donovan, J., & Smyth, B. (2005b). Trust in Recommender Systems. In *Proceedings of the 10th International Conference on Intelligent User Interfaces* (pp. 167–174). New York, NY, USA: ACM.
- O'Mahony, M., Hurley, N., & Silvestre, G. (2005). Recommender systems: Attack types and strategies. *Aaai*, 334–339. Retrieved from <http://www.aaai.org/Papers/AAAI/2005/AAAI05-053.pdf>
- Odić, A., Tkalčić, M., Tasić, J. F., & Košir, A. (2012). Relevant context in a movie recommender system: Users' opinion vs. statistical detection. *CEUR Workshop Proceedings*, 889. <https://doi.org/10.1.1.416.5326>
- Palmisano, C., Tuzhilin, A., & Gorgoglione, M. (2008). Using Context to Improve Predictive

- Modeling of Customers in Personalization Applications. *IEEE Transactions on Knowledge and Data Engineering*, 20(11), 1535–1549.
- Park, W.-I., Park, J.-H., Kim, Y.-K., & Kang, J.-H. (2010). An efficient context-aware personalization technique in ubiquitous environments. *Proceedings of the 4th International Conference on Ubiquitous Information Management and Communication - ICUIMC '10*, 1. <https://doi.org/10.1145/2108616.2108689>
- Paul-Stueve, T., & Wachsmuth, S. (2012). Towards a Social Context Model and Architecture for Large-Scale Pervasive Environments. *IEEE International Conference on Pervasive Computing and Communications Workshops*, (March), 619–624. <https://doi.org/10.1109/PerComW.2012.6197589>
- Pazzani, M. J., & Billsus, D. (2007). The Adaptive Web. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Eds.) (pp. 325–341). Berlin, Heidelberg: Springer-Verlag.
- Plutchick, R., & Kellerman, H. (1980). EMOTION: Theory, Research, and Experience. In R. Plutchik & H. Kellerman (Eds.), *Theories of Emotion*. Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-558701-3.50001-6>
- Plutchik, R. (2001). The Nature of Emotions. *American Scientist*, 89, 344. <https://doi.org/10.1511/2001.4.344>
- Qin, W., Shi, Y., & Suo, Y. (2007). Ontology-Based Context-Aware Middleware for Smart Spaces. *Tsinghua Science and Technology*, 12(6), 707–713. [https://doi.org/10.1016/S1007-0214\(07\)70179-7](https://doi.org/10.1016/S1007-0214(07)70179-7)
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., & Riedl, J. (1994). GroupLens: An Open Architecture for Collaborative Filtering of Netnews. *Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work*, 175–186. <https://doi.org/10.1145/192844.192905>
- Resnick, P., & Varian, H. R. (1997). Recommender Systems. *Commun. ACM*, 40(3), 56–58.
- Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender Systems Handbook*. Springer-Verlag (Vol. 54). <https://doi.org/10.1007/978-0-387-85820-3>
- Ricci, F., Rokach, L., Shapira, B., & Kantor, P. B. (2015). *Recommender Systems Handbook* (2nd ed.). New York, NY, USA: Springer-Verlag New York, Inc.
- Riedl, J., & Jameson, A. (2007). Advanced Topics in Recommendation. In *Proceedings of the 12th International Conference on Intelligent User Interfaces* (p. 11). New York, NY, USA: ACM.
- Salles, A., & Willrich, R. (2015). Recommending Web Service Based on Ontologies for Digital Repositories. In *Proceedings of the 21st Brazilian Symposium on Multimedia and the Web*

- (pp. 65–72). New York, NY, USA: ACM.
- Sarwar, B., Karypis, G., Konstan, J., & Reidl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the Tenth International Conference on World Wide Web - WWW '01*, 285–295. <https://doi.org/10.1145/371920.372071>
- Sarwat, M., Levandoski, J. J., Eldawy, A., & Mokbel, M. F. (2014). LARS*: An Efficient and Scalable Location-Aware Recommender System. *IEEE Transactions on Knowledge and Data Engineering*, 26(6), 1384–1399.
- Schröder, M., Pirker, H., & Lamolle, M. (2006). First suggestions for an emotion annotation and representation language. *Proceedings of LREC'06 Workshop on Corpora for Research on Emotion and Affect*, 6, 88–92. Retrieved from http://www2.dfki.de/~schroed/articles/schroeder_etal2006a.pdf
- Shardanand, U., & Maes, P. (1995). Social Information Filtering: Algorithms for Automating “Word of Mouth.” In *Proceedings of the Conference on Human Factors in Computing Systems (CHI95)*, 210–217. Retrieved from <http://dl.acm.org/citation.cfm?id=223931>
- Somerville, R. M. (1971). Family in Society. *The Family Coordinator*, 20(1), 82. <https://doi.org/10.2307/582941>
- Sotsenko, A., Jansen, M., & Milrad, M. (2015). Using a Rich Context Model for People-to-People Recommendation. *Proceedings - 2015 International Conference on Future Internet of Things and Cloud, FiCloud 2015 and 2015 International Conference on Open and Big Data, OBD 2015*, 703–708. <https://doi.org/10.1109/FiCloud.2015.68>
- Stevenson, G., Knox, S., Dobson, S., & Nixon, P. (2009). Ontonym: A Collection of Upper Ontologies for Developing Pervasive Systems. *Proceedings of the 1st Workshop on Context, Information and Ontologies*, 1–8. <https://doi.org/http://doi.acm.org/10.1145/1552262.1552271>
- Winkler, W. E. (1990). String Comparator Metrics and Enhanced Decision Rules in the Fellegi-Sunter Model of Record Linkage. *Proceedings of the Section on Survey Research, American Statistical Association*, (January 1990), 354–359. https://doi.org/10.1007/978-1-4612-2856-1_101
- Xu, J., & Dong, W. (2012). Object-oriented and ontology context-aware modeling based on XML. *Proceedings of 2nd International Conference on Computer Science and Network Technology, ICCSNT 2012*, 1795–1800. <https://doi.org/10.1109/ICCSNT.2012.6526268>
- Yu, Z., Zhou, X., Yu, Z., Park, J. H., & Ma, J. (2008). iMuseum: A scalable context-aware intelligent museum system. *Computer Communications*, 31(18), 4376–4382. <https://doi.org/10.1016/j.comcom.2008.05.004>
- Zhang, D., Gu, T., & Wang, X. (2005). Enabling Context-aware Smart Home with Semantic

-
- Technology. *International Journal of Human-Friendly Welfare Robotic Systems*, 12–20.
- Zheng, Y. (2015). A User’s Guide to CARSKit, 1–7. Retrieved from <http://arxiv.org/abs/1511.03780>
- Zheng, Y., Burke, R., & Mobasher, B. (2014). Splitting Approaches for Context-aware Recommendation: An Empirical Study. In *Proceedings of the 29th Annual ACM Symposium on Applied Computing* (pp. 274–279). New York, NY, USA: ACM.
- Zoeter, O. (2015). Recommendations in Travel. In *Proceedings of the 9th ACM Conference on Recommender Systems* (p. 234). New York, NY, USA: ACM.

Anexos

Anexo 1: Resultados extendidos de experimentación

Del proceso de experimentación se ha obtenido muchos datos de métricas y no todas ellas se han presentado en el texto. De hecho, se han realizado tablas resumidas de los datos, con el fin de facilitar la lectura de los resultados con la explicación de su comportamiento.

Es por ello, que se presentan todos los datos recopilados en detalle de cada experimento realizado, con el fin de transparentar la sección de Experimentos y Análisis de Resultados. A continuación, las tablas detalladas de cada experimento:

	Yelp Beauty Spas			Yelp Hotels		
	BiasedMF	ItemKNN	UserKNN	BiasedMF	ItemKNN	UserKNN
MAE	0.9763	1.0330	1.0330	0.9094	1.0157	1.0140
RMSE	1.2578	1.3275	1.3269	1.1503	1.2335	1.2288
Pre@5	0.0033	0.0034	0.0029	0.0117	0.0212	0.0203
Pre@10	0.0027	0.0055	0.0053	0.0102	0.0185	0.0178
Rec@5	0.0161	0.0164	0.0140	0.0576	0.1045	0.1001
Rec@10	0.0267	0.0542	0.0520	0.1006	0.1827	0.1757
MAP	0.0098	0.0148	0.0121	0.0344	0.0683	0.0660
NDCG	0.0137	0.0237	0.0210	0.0498	0.0947	0.0912
AUC	0.5134	0.5269	0.5258	0.5494	0.5900	0.5864

Tabla 16: Resultados extendidos de métricas de evaluación de algoritmos Baseline sobre datasets Yelp Beauty Spas y Yelp Hotels

		Yelp Beauty Spas														
		CAMF	CAMF	CAMF	CAMF	IS-	IS-	IS-	UIS-	UIS-	UIS-	US-	US-	US-		
		C	CI	CU	_CUCI	Biased	ItemK	UserK	Biased	ItemK	UserK	Biased	ItemK	UserK		
Variante						MF	NN	NN	MF	NN	NN	MF	NN	NN		
MAE	ALL	0.9443	0.9597	0.9571	0.9988	0.9792	1.0340	1.0333	0.9781	1.0341	1.0332	0.9761	1.0334	1.0329		
	Emotions	0.9496	0.9827	0.9509	1.0240	0.9792	1.0337	1.0330	0.9787	1.0337	1.0331	0.9772	1.0330	1.0332		
	Environmental	0.9716	0.9659	0.9533	1.0003	0.9767	1.0330	1.0330	0.9763	1.0330	1.0330	0.9753	1.0330	1.0330		
	Family	0.9703	0.9789	0.9519	1.0105	0.9760	1.0333	1.0333	0.9768	1.0334	1.0332	0.9772	1.0331	1.0331		
	Friendship	0.9750	0.9591	0.9470	0.9912	0.9775	1.0331	1.0333	0.9785	1.0331	1.0333	0.9771	1.0331	1.0329		
	Interpersonal_Relationship	0.9737	0.9815	0.9519	1.0150	0.9775	1.0333	1.0333	0.9799	1.0335	1.0331	0.9772	1.0331	1.0327		
	Mood	0.9757	0.9538	0.9486	0.9866	0.9774	1.0331	1.0332	0.9773	1.0331	1.0332	0.9776	1.0330	1.0330		
	Negative_Emotions	0.9565	0.9691	0.9520	0.9948	0.9767	1.0324	1.0330	0.9759	1.0323	1.0330	0.9763	1.0330	1.0330		
	Other_Emotions	0.9549	0.9670	0.9500	1.0074	0.9787	1.0338	1.0329	0.9783	1.0338	1.0329	0.9781	1.0330	1.0330		
	Personal	0.9495	0.9835	0.9537	1.0258	0.9783	1.0337	1.0330	0.9779	1.0337	1.0331	0.9773	1.0330	1.0332		
	Pet	0.9795	0.9516	0.9485	0.9857	0.9777	1.0332	1.0329	0.9766	1.0334	1.0328	0.9775	1.0334	1.0328		
	Positive_Emotions	0.9746	0.9577	0.9501	1.0001	0.9792	1.0332	1.0329	0.9786	1.0336	1.0329	0.9770	1.0334	1.0329		
	Social	0.9745	0.9838	0.9514	1.0151	0.9786	1.0333	1.0333	0.9781	1.0337	1.0330	0.9782	1.0335	1.0327		
RMSE	ALL	1.2277	1.4269	1.4491	1.2902	1.2591	1.3280	1.3272	1.2590	1.3280	1.3272	1.2582	1.3277	1.3269		
	Emotions	1.2313	1.3600	1.3055	1.2980	1.2593	1.3279	1.3269	1.2599	1.3279	1.3270	1.2591	1.3275	1.3270		
	Environmental	1.2580	1.3186	1.3051	1.2800	1.2582	1.3275	1.3269	1.2572	1.3275	1.3269	1.2570	1.3275	1.3269		
	Family	1.2515	1.3458	1.3063	1.2925	1.2579	1.3276	1.3271	1.2578	1.3277	1.3271	1.2586	1.3276	1.3269		
	Friendship	1.2590	1.3049	1.2985	1.2691	1.2593	1.3275	1.3272	1.2600	1.3276	1.3272	1.2587	1.3276	1.3269		
	Interpersonal_Relationship	1.2522	1.3552	1.3048	1.2972	1.2585	1.3277	1.3272	1.2603	1.3277	1.3271	1.2589	1.3276	1.3268		
	Mood	1.2594	1.2935	1.3008	1.2628	1.2586	1.3275	1.3269	1.2589	1.3275	1.3269	1.2595	1.3275	1.3269		
	Negative_Emotions	1.2386	1.3320	1.3043	1.2781	1.2586	1.3270	1.3269	1.2570	1.3270	1.3269	1.2580	1.3275	1.3269		
	Other_Emotions	1.2431	1.3169	1.3030	1.2789	1.2593	1.3279	1.3269	1.2593	1.3279	1.3269	1.2597	1.3275	1.3269		
	Personal	1.2294	1.3642	1.3071	1.3009	1.2591	1.3278	1.3269	1.2579	1.3278	1.3270	1.2583	1.3275	1.3270		
	Pet	1.2608	1.2854	1.3005	1.2613	1.2584	1.3276	1.3269	1.2568	1.3277	1.3268	1.2589	1.3277	1.3268		
	Positive_Emotions	1.2584	1.3019	1.3011	1.2709	1.2595	1.3276	1.3269	1.2588	1.3277	1.3269	1.2587	1.3276	1.3269		
	Social	1.2535	1.3587	1.3069	1.2985	1.2583	1.3277	1.3272	1.2591	1.3278	1.3271	1.2599	1.3278	1.3268		

Pre@5	ALL	0.0031	0.0010	0.0010	0.0027	0.0028	0.0030	0.0026	0.0029	0.0029	0.0026	0.0033	0.0032	0.0028
	Emotions	0.0029	0.0013	0.0015	0.0035	0.0029	0.0032	0.0028	0.0029	0.0032	0.0028	0.0035	0.0035	0.0029
	Environmental	0.0037	0.0011	0.0015	0.0031	0.0035	0.0038	0.0032	0.0035	0.0038	0.0032	0.0036	0.0038	0.0032
	Family	0.0033	0.0012	0.0016	0.0036	0.0033	0.0031	0.0024	0.0033	0.0031	0.0024	0.0034	0.0037	0.0031
	Friendship	0.0039	0.0011	0.0016	0.0031	0.0034	0.0039	0.0031	0.0036	0.0039	0.0030	0.0034	0.0038	0.0030
	Interpersonal_Relationship	0.0036	0.0012	0.0015	0.0039	0.0034	0.0036	0.0029	0.0032	0.0035	0.0028	0.0032	0.0036	0.0029
	Mood	0.0038	0.0012	0.0016	0.0028	0.0035	0.0037	0.0031	0.0034	0.0037	0.0031	0.0035	0.0039	0.0032
	Negative_Emotions	0.0032	0.0013	0.0015	0.0031	0.0035	0.0035	0.0030	0.0033	0.0035	0.0030	0.0035	0.0038	0.0031
	Other_Emotions	0.0036	0.0012	0.0016	0.0031	0.0034	0.0037	0.0029	0.0033	0.0037	0.0029	0.0036	0.0037	0.0030
	Personal	0.0031	0.0013	0.0014	0.0036	0.0030	0.0032	0.0028	0.0029	0.0032	0.0028	0.0033	0.0035	0.0029
	Pet	0.0037	0.0011	0.0016	0.0028	0.0036	0.0040	0.0032	0.0036	0.0038	0.0032	0.0036	0.0038	0.0032
	Positive_Emotions	0.0035	0.0012	0.0014	0.0033	0.0031	0.0035	0.0030	0.0030	0.0035	0.0030	0.0035	0.0037	0.0030
	Social	0.0035	0.0011	0.0016	0.0036	0.0032	0.0035	0.0028	0.0032	0.0034	0.0028	0.0035	0.0034	0.0029
Pre@1 0	ALL	0.0027	0.0010	0.0010	0.0024	0.0023	0.0048	0.0048	0.0024	0.0048	0.0047	0.0028	0.0054	0.0052
	Emotions	0.0026	0.0012	0.0014	0.0030	0.0024	0.0050	0.0048	0.0023	0.0050	0.0048	0.0028	0.0056	0.0054
	Environmental	0.0030	0.0011	0.0014	0.0026	0.0029	0.0058	0.0056	0.0027	0.0058	0.0056	0.0029	0.0059	0.0056
	Family	0.0028	0.0012	0.0015	0.0029	0.0027	0.0053	0.0051	0.0027	0.0053	0.0051	0.0028	0.0058	0.0055
	Friendship	0.0030	0.0011	0.0015	0.0025	0.0028	0.0059	0.0055	0.0029	0.0058	0.0055	0.0028	0.0059	0.0055
	Interpersonal_Relationship	0.0028	0.0012	0.0015	0.0032	0.0026	0.0054	0.0052	0.0026	0.0054	0.0051	0.0027	0.0057	0.0054
	Mood	0.0030	0.0012	0.0015	0.0024	0.0029	0.0059	0.0056	0.0028	0.0059	0.0056	0.0028	0.0059	0.0056
	Negative_Emotions	0.0026	0.0013	0.0014	0.0027	0.0027	0.0048	0.0046	0.0027	0.0048	0.0046	0.0028	0.0058	0.0055
	Other_Emotions	0.0029	0.0011	0.0014	0.0027	0.0027	0.0056	0.0053	0.0027	0.0056	0.0053	0.0029	0.0058	0.0055
	Personal	0.0026	0.0012	0.0013	0.0031	0.0024	0.0050	0.0048	0.0024	0.0050	0.0048	0.0028	0.0055	0.0054
	Pet	0.0030	0.0011	0.0014	0.0023	0.0029	0.0060	0.0057	0.0029	0.0060	0.0057	0.0029	0.0060	0.0057
	Positive_Emotions	0.0028	0.0012	0.0014	0.0028	0.0025	0.0052	0.0050	0.0024	0.0052	0.0050	0.0027	0.0058	0.0055
	Social	0.0028	0.0012	0.0014	0.0030	0.0026	0.0054	0.0052	0.0026	0.0053	0.0051	0.0028	0.0056	0.0054
Rec@5	ALL	0.0151	0.0050	0.0050	0.0135	0.0136	0.0147	0.0129	0.0141	0.0142	0.0127	0.0164	0.0156	0.0136
	Emotions	0.0141	0.0065	0.0072	0.0174	0.0140	0.0152	0.0131	0.0143	0.0152	0.0131	0.0169	0.0166	0.0140
	Environmental	0.0171	0.0053	0.0073	0.0144	0.0166	0.0165	0.0143	0.0165	0.0165	0.0143	0.0168	0.0167	0.0143

	Family	0.0159	0.0057	0.0077	0.0171	0.0156	0.0143	0.0115	0.0155	0.0141	0.0116	0.0162	0.0164	0.0142
	Friendship	0.0179	0.0051	0.0074	0.0144	0.0160	0.0169	0.0141	0.0170	0.0167	0.0138	0.0162	0.0166	0.0138
	Interpersonal_Relationship	0.0175	0.0058	0.0074	0.0185	0.0160	0.0163	0.0136	0.0151	0.0160	0.0131	0.0156	0.0163	0.0135
	Mood	0.0178	0.0056	0.0073	0.0131	0.0161	0.0163	0.0140	0.0159	0.0163	0.0140	0.0163	0.0167	0.0143
	Negative_Emotions	0.0154	0.0060	0.0072	0.0151	0.0166	0.0156	0.0137	0.0154	0.0156	0.0137	0.0166	0.0167	0.0143
	Other_Emotions	0.0172	0.0057	0.0078	0.0148	0.0162	0.0165	0.0136	0.0158	0.0165	0.0136	0.0171	0.0166	0.0138
	Personal	0.0153	0.0061	0.0068	0.0174	0.0146	0.0149	0.0131	0.0143	0.0150	0.0131	0.0162	0.0166	0.0140
	Pet	0.0170	0.0051	0.0072	0.0128	0.0166	0.0166	0.0143	0.0165	0.0162	0.0144	0.0166	0.0162	0.0144
	Positive_Emotions	0.0169	0.0056	0.0068	0.0159	0.0146	0.0154	0.0139	0.0143	0.0155	0.0137	0.0166	0.0167	0.0140
	Social	0.0166	0.0055	0.0076	0.0175	0.0154	0.0162	0.0135	0.0151	0.0154	0.0131	0.0165	0.0158	0.0136
Rec@1 0	ALL	0.0261	0.0098	0.0100	0.0239	0.0227	0.0478	0.0469	0.0231	0.0475	0.0467	0.0274	0.0536	0.0517
	Emotions	0.0248	0.0118	0.0132	0.0295	0.0234	0.0481	0.0466	0.0225	0.0481	0.0466	0.0273	0.0542	0.0522
	Environmental	0.0280	0.0102	0.0136	0.0247	0.0269	0.0536	0.0518	0.0257	0.0536	0.0518	0.0270	0.0545	0.0522
	Family	0.0268	0.0115	0.0139	0.0277	0.0259	0.0503	0.0486	0.0257	0.0501	0.0488	0.0266	0.0543	0.0525
	Friendship	0.0278	0.0104	0.0141	0.0239	0.0259	0.0538	0.0516	0.0267	0.0536	0.0513	0.0266	0.0544	0.0519
	Interpersonal_Relationship	0.0271	0.0116	0.0142	0.0310	0.0251	0.0517	0.0499	0.0249	0.0514	0.0495	0.0257	0.0542	0.0517
	Mood	0.0283	0.0110	0.0135	0.0222	0.0270	0.0541	0.0520	0.0262	0.0541	0.0520	0.0264	0.0545	0.0523
	Negative_Emotions	0.0253	0.0120	0.0132	0.0256	0.0262	0.0451	0.0436	0.0254	0.0451	0.0438	0.0267	0.0544	0.0526
	Other_Emotions	0.0278	0.0106	0.0136	0.0255	0.0261	0.0527	0.0500	0.0253	0.0527	0.0500	0.0277	0.0544	0.0521
	Personal	0.0249	0.0114	0.0129	0.0304	0.0233	0.0481	0.0468	0.0235	0.0481	0.0468	0.0270	0.0542	0.0522
	Pet	0.0282	0.0104	0.0132	0.0215	0.0266	0.0544	0.0522	0.0264	0.0542	0.0523	0.0266	0.0542	0.0523
	Positive_Emotions	0.0268	0.0112	0.0133	0.0268	0.0242	0.0486	0.0472	0.0234	0.0485	0.0470	0.0260	0.0542	0.0519
	Social	0.0272	0.0113	0.0136	0.0295	0.0248	0.0516	0.0498	0.0250	0.0511	0.0494	0.0271	0.0538	0.0517
MAP	ALL	0.0090	0.0028	0.0030	0.0081	0.0080	0.0131	0.0111	0.0087	0.0128	0.0110	0.0097	0.0145	0.0120
	Emotions	0.0085	0.0037	0.0044	0.0106	0.0085	0.0135	0.0111	0.0082	0.0136	0.0111	0.0103	0.0150	0.0121
	Environmental	0.0105	0.0031	0.0043	0.0089	0.0099	0.0146	0.0121	0.0099	0.0146	0.0121	0.0102	0.0149	0.0122
	Family	0.0097	0.0035	0.0048	0.0106	0.0097	0.0137	0.0115	0.0094	0.0135	0.0116	0.0099	0.0147	0.0122
	Friendship	0.0107	0.0030	0.0043	0.0092	0.0099	0.0148	0.0121	0.0103	0.0148	0.0120	0.0102	0.0149	0.0121
	Interpersonal_Relationship	0.0101	0.0034	0.0044	0.0111	0.0097	0.0143	0.0117	0.0092	0.0140	0.0116	0.0093	0.0147	0.0120

Personal	0.5126	0.5058	0.5065	0.5153	0.5119	0.5244	0.5235	0.5119	0.5244	0.5235	0.5138	0.5273	0.5262
Pet	0.5150	0.5056	0.5071	0.5114	0.5141	0.5294	0.5279	0.5141	0.5293	0.5279	0.5141	0.5293	0.5279
Positive_Emotions	0.5139	0.5057	0.5069	0.5138	0.5126	0.5256	0.5245	0.5121	0.5256	0.5244	0.5134	0.5284	0.5268
Social	0.5140	0.5058	0.5070	0.5150	0.5128	0.5265	0.5253	0.5129	0.5263	0.5252	0.5140	0.5276	0.5262

Tabla 17: Métricas de evaluación extendida sobre dataset Yelp Beauty Spas

		Yelp Hotels													
Variante	CAMF _C	CAMF _CI	CAMF _CU	CAMF _CUCI	IS-	IS-	IS-	UIS-	UIS-	UIS-	US-	US-	US-		
					Biased MF	ItemK NN	UserK NN	Biased MF	ItemK NN	UserK NN	Biased MF	ItemK NN	UserK NN		
MAE	ALL	0.8934	0.9862	1.0184	0.9210	0.9111	1.0172	1.0147	0.9105	1.0172	1.0147	0.9072	1.0157	1.0140	
	Emotions	0.8961	0.9486	0.9348	0.9335	0.9090	1.0171	1.0148	0.9086	1.0171	1.0148	0.9089	1.0157	1.0140	
	Environmental	0.9062	0.9411	0.9319	0.9305	0.9118	1.0167	1.0143	0.9079	1.0167	1.0143	0.9079	1.0157	1.0140	
	Family	0.9105	0.9393	0.9328	0.9333	0.9098	1.0164	1.0142	0.9132	1.0164	1.0142	0.9094	1.0157	1.0140	
	Friendship	0.9115	0.9277	0.9274	0.9195	0.9090	1.0166	1.0143	0.9068	1.0166	1.0143	0.9083	1.0157	1.0140	
	Interpersonal_Relationship	0.9062	0.9475	0.9292	0.9365	0.9106	1.0164	1.0144	0.9096	1.0164	1.0144	0.9095	1.0157	1.0140	
	Mood	0.9088	0.9308	0.9336	0.9206	0.9083	1.0159	1.0143	0.9094	1.0159	1.0143	0.9093	1.0157	1.0140	
	Negative_Emotions	0.9049	0.9358	0.9285	0.9165	0.9072	1.0145	1.0138	0.9084	1.0145	1.0138	0.9089	1.0157	1.0140	
	Other_Emotions	0.9036	0.9309	0.9330	0.9257	0.9094	1.0154	1.0143	0.9087	1.0154	1.0143	0.9085	1.0157	1.0140	
	Personal	0.8960	0.9538	0.9319	0.9343	0.9079	1.0171	1.0148	0.9070	1.0171	1.0148	0.9096	1.0157	1.0140	
	Pet	0.9121	0.9270	0.9319	0.9206	0.9089	1.0156	1.0140	0.9083	1.0156	1.0140	0.9071	1.0157	1.0140	
	Positive_Emotions	0.9087	0.9324	0.9292	0.9252	0.9104	1.0158	1.0140	0.9103	1.0158	1.0140	0.9084	1.0157	1.0140	
Social	0.9081	0.9509	0.9322	0.9429	0.9108	1.0162	1.0141	0.9116	1.0162	1.0141	0.9071	1.0157	1.0140		
RMSE	ALL	1.1352	1.3004	1.3507	1.1676	1.1502	1.2335	1.2292	1.1491	1.2335	1.2292	1.1481	1.2335	1.2288	
	Emotions	1.1363	1.2326	1.1991	1.1731	1.1481	1.2335	1.2293	1.1482	1.2335	1.2293	1.1495	1.2335	1.2288	
	Environmental	1.1464	1.2052	1.1983	1.1676	1.1528	1.2335	1.2290	1.1487	1.2335	1.2290	1.1487	1.2335	1.2288	
	Family	1.1500	1.2117	1.1981	1.1726	1.1495	1.2341	1.2290	1.1534	1.2341	1.2290	1.1500	1.2335	1.2288	
	Friendship	1.1471	1.1860	1.1934	1.1567	1.1498	1.2340	1.2290	1.1477	1.2340	1.2290	1.1489	1.2335	1.2288	
	Interpersonal_Relationship	1.1476	1.2261	1.1944	1.1763	1.1505	1.2337	1.2291	1.1498	1.2337	1.2291	1.1499	1.2335	1.2288	
	Mood	1.1447	1.1882	1.1999	1.1568	1.1497	1.2336	1.2290	1.1491	1.2336	1.2290	1.1496	1.2335	1.2288	
	Negative_Emotions	1.1393	1.2070	1.1952	1.1557	1.1480	1.2312	1.2278	1.1497	1.2312	1.2278	1.1489	1.2335	1.2288	
	Other_Emotions	1.1390	1.1945	1.1977	1.1621	1.1496	1.2332	1.2289	1.1494	1.2332	1.2289	1.1502	1.2335	1.2288	
	Personal	1.1380	1.2391	1.1985	1.1730	1.1477	1.2335	1.2293	1.1460	1.2335	1.2293	1.1506	1.2335	1.2288	
	Pet	1.1473	1.1827	1.1967	1.1564	1.1502	1.2335	1.2288	1.1486	1.2335	1.2288	1.1492	1.2335	1.2288	
	Positive_Emotions	1.1465	1.2000	1.1963	1.1636	1.1505	1.2328	1.2288	1.1505	1.2328	1.2288	1.1494	1.2335	1.2288	

	Social	1.1491	1.2322	1.1979	1.1821	1.1507	1.2332	1.2289	1.1510	1.2332	1.2289	1.1478	1.2335	1.2288
Pre@5	ALL	0.0134	0.0018	0.0016	0.0111	0.0102	0.0188	0.0179	0.0104	0.0188	0.0179	0.0118	0.0212	0.0203
	Emotions	0.0128	0.0044	0.0072	0.0114	0.0108	0.0189	0.0182	0.0106	0.0189	0.0182	0.0119	0.0215	0.0205
	Environmental	0.0134	0.0043	0.0075	0.0102	0.0118	0.0213	0.0206	0.0124	0.0213	0.0206	0.0122	0.0216	0.0207
	Family	0.0133	0.0043	0.0079	0.0111	0.0113	0.0214	0.0201	0.0112	0.0214	0.0201	0.0122	0.0217	0.0207
	Friendship	0.0138	0.0048	0.0081	0.0106	0.0123	0.0220	0.0209	0.0121	0.0220	0.0209	0.0125	0.0220	0.0210
	Interpersonal_Relationship	0.0134	0.0045	0.0076	0.0115	0.0104	0.0216	0.0202	0.0110	0.0216	0.0202	0.0124	0.0216	0.0206
	Mood	0.0136	0.0040	0.0079	0.0102	0.0127	0.0219	0.0208	0.0125	0.0219	0.0208	0.0126	0.0220	0.0209
	Negative_Emotions	0.0136	0.0051	0.0075	0.0111	0.0101	0.0164	0.0154	0.0102	0.0164	0.0154	0.0121	0.0219	0.0208
	Other_Emotions	0.0122	0.0041	0.0080	0.0104	0.0115	0.0214	0.0202	0.0116	0.0214	0.0202	0.0124	0.0218	0.0208
	Personal	0.0125	0.0043	0.0077	0.0117	0.0109	0.0190	0.0182	0.0107	0.0190	0.0182	0.0122	0.0215	0.0205
	Pet	0.0137	0.0040	0.0079	0.0099	0.0128	0.0219	0.0210	0.0121	0.0219	0.0210	0.0124	0.0219	0.0210
	Positive_Emotions	0.0130	0.0043	0.0077	0.0112	0.0118	0.0216	0.0206	0.0118	0.0216	0.0206	0.0120	0.0217	0.0208
	Social	0.0132	0.0039	0.0076	0.0118	0.0112	0.0213	0.0201	0.0110	0.0213	0.0201	0.0121	0.0215	0.0205
Pre@10	ALL	0.0113	0.0020	0.0017	0.0092	0.0088	0.0169	0.0163	0.0089	0.0169	0.0163	0.0100	0.0185	0.0178
	Emotions	0.0110	0.0043	0.0066	0.0097	0.0091	0.0171	0.0164	0.0092	0.0171	0.0164	0.0102	0.0188	0.0180
	Environmental	0.0112	0.0042	0.0067	0.0088	0.0101	0.0184	0.0176	0.0103	0.0184	0.0176	0.0104	0.0189	0.0181
	Family	0.0112	0.0040	0.0068	0.0093	0.0096	0.0186	0.0178	0.0095	0.0186	0.0178	0.0102	0.0190	0.0182
	Friendship	0.0116	0.0045	0.0070	0.0091	0.0101	0.0189	0.0181	0.0099	0.0189	0.0181	0.0106	0.0192	0.0184
	Interpersonal_Relationship	0.0113	0.0042	0.0068	0.0097	0.0090	0.0186	0.0178	0.0092	0.0186	0.0178	0.0105	0.0189	0.0181
	Mood	0.0113	0.0041	0.0068	0.0087	0.0107	0.0192	0.0183	0.0106	0.0192	0.0183	0.0106	0.0193	0.0184
	Negative_Emotions	0.0116	0.0046	0.0065	0.0094	0.0088	0.0161	0.0157	0.0089	0.0161	0.0157	0.0104	0.0191	0.0183
	Other_Emotions	0.0107	0.0041	0.0069	0.0091	0.0098	0.0186	0.0179	0.0098	0.0186	0.0179	0.0105	0.0190	0.0182
	Personal	0.0109	0.0043	0.0068	0.0099	0.0092	0.0171	0.0164	0.0092	0.0171	0.0164	0.0102	0.0188	0.0180
	Pet	0.0113	0.0040	0.0069	0.0085	0.0105	0.0191	0.0184	0.0102	0.0191	0.0184	0.0106	0.0192	0.0184
	Positive_Emotions	0.0112	0.0041	0.0069	0.0095	0.0099	0.0190	0.0181	0.0098	0.0190	0.0181	0.0105	0.0190	0.0182
	Social	0.0111	0.0038	0.0069	0.0097	0.0093	0.0184	0.0178	0.0093	0.0184	0.0178	0.0103	0.0188	0.0180
Rec@5	ALL	0.0663	0.0089	0.0082	0.0550	0.0502	0.0926	0.0882	0.0512	0.0926	0.0882	0.0582	0.1045	0.1001
	Emotions	0.0625	0.0215	0.0352	0.0556	0.0525	0.0921	0.0889	0.0516	0.0921	0.0889	0.0580	0.1045	0.1004

	Environmental	0.0651	0.0205	0.0364	0.0493	0.0571	0.1033	0.0998	0.0600	0.1033	0.0998	0.0590	0.1044	0.1005
	Family	0.0643	0.0207	0.0383	0.0539	0.0544	0.1028	0.0976	0.0542	0.1028	0.0976	0.0588	0.1046	0.1007
	Friendship	0.0665	0.0233	0.0389	0.0509	0.0589	0.1046	0.1005	0.0582	0.1046	0.1005	0.0599	0.1046	0.1008
	Interpersonal_Relationship	0.0654	0.0220	0.0372	0.0563	0.0508	0.1041	0.0985	0.0534	0.1041	0.0985	0.0604	0.1045	0.1007
	Mood	0.0644	0.0192	0.0378	0.0487	0.0601	0.1042	0.0998	0.0594	0.1042	0.0998	0.0603	0.1046	0.1006
	Negative_Emotions	0.0651	0.0245	0.0360	0.0534	0.0486	0.0782	0.0747	0.0490	0.0782	0.0747	0.0580	0.1046	0.1006
	Other_Emotions	0.0588	0.0200	0.0385	0.0500	0.0556	0.1027	0.0978	0.0557	0.1027	0.0978	0.0595	0.1046	0.1005
	Personal	0.0611	0.0212	0.0378	0.0569	0.0528	0.0923	0.0891	0.0519	0.0923	0.0891	0.0595	0.1045	0.1004
	Pet	0.0653	0.0191	0.0377	0.0470	0.0608	0.1044	0.1007	0.0577	0.1044	0.1007	0.0592	0.1046	0.1006
	Positive_Emotions	0.0622	0.0205	0.0371	0.0537	0.0567	0.1037	0.0995	0.0568	0.1037	0.0995	0.0578	0.1045	0.1007
	Social	0.0647	0.0192	0.0369	0.0578	0.0550	0.1030	0.0984	0.0537	0.1030	0.0984	0.0593	0.1045	0.1005
	ALL	0.1118	0.0193	0.0164	0.0913	0.0867	0.1666	0.1607	0.0875	0.1666	0.1607	0.0992	0.1827	0.1757
	Emotions	0.1072	0.0419	0.0639	0.0948	0.0888	0.1657	0.1601	0.0899	0.1657	0.1601	0.0992	0.1828	0.1760
	Environmental	0.1086	0.0403	0.0645	0.0855	0.0977	0.1785	0.1715	0.1001	0.1785	0.1715	0.1004	0.1828	0.1758
	Family	0.1082	0.0388	0.0662	0.0901	0.0929	0.1786	0.1722	0.0916	0.1786	0.1722	0.0983	0.1828	0.1762
	Friendship	0.1109	0.0431	0.0673	0.0877	0.0968	0.1803	0.1748	0.0954	0.1803	0.1748	0.1021	0.1829	0.1770
	Interpersonal_Relationship	0.1095	0.0407	0.0659	0.0944	0.0877	0.1796	0.1734	0.0900	0.1796	0.1734	0.1024	0.1828	0.1763
Rec@1	Mood	0.1075	0.0388	0.0651	0.0827	0.1015	0.1818	0.1758	0.1013	0.1818	0.1758	0.1012	0.1829	0.1769
0	Negative_Emotions	0.1108	0.0444	0.0625	0.0904	0.0845	0.1540	0.1514	0.0854	0.1540	0.1514	0.0997	0.1828	0.1767
	Other_Emotions	0.1032	0.0394	0.0661	0.0874	0.0944	0.1782	0.1726	0.0946	0.1782	0.1726	0.1015	0.1827	0.1761
	Personal	0.1060	0.0415	0.0664	0.0964	0.0896	0.1659	0.1603	0.0893	0.1659	0.1603	0.0997	0.1828	0.1760
	Pet	0.1081	0.0379	0.0655	0.0815	0.1006	0.1823	0.1769	0.0973	0.1823	0.1769	0.1011	0.1829	0.1769
	Positive_Emotions	0.1076	0.0397	0.0662	0.0911	0.0957	0.1824	0.1754	0.0942	0.1824	0.1754	0.1010	0.1829	0.1765
	Social	0.1085	0.0372	0.0673	0.0955	0.0912	0.1792	0.1735	0.0905	0.1792	0.1735	0.1011	0.1828	0.1762
	ALL	0.0389	0.0053	0.0050	0.0337	0.0300	0.0589	0.0555	0.0301	0.0589	0.0555	0.0347	0.0683	0.0660
	Emotions	0.0366	0.0133	0.0218	0.0327	0.0311	0.0588	0.0552	0.0314	0.0588	0.0552	0.0349	0.0685	0.0662
MAP	Environmental	0.0389	0.0125	0.0225	0.0303	0.0346	0.0684	0.0654	0.0354	0.0684	0.0654	0.0355	0.0686	0.0661
	Family	0.0379	0.0121	0.0232	0.0322	0.0328	0.0664	0.0640	0.0325	0.0664	0.0640	0.0350	0.0687	0.0663
	Friendship	0.0394	0.0138	0.0232	0.0304	0.0352	0.0684	0.0661	0.0344	0.0684	0.0661	0.0355	0.0688	0.0664

	Interpersonal_Relationship	0.0388	0.0131	0.0230	0.0339	0.0299	0.0676	0.0647	0.0307	0.0676	0.0647	0.0364	0.0686	0.0663
	Mood	0.0382	0.0118	0.0233	0.0295	0.0359	0.0685	0.0660	0.0356	0.0685	0.0660	0.0360	0.0689	0.0666
	Negative_Emotions	0.0379	0.0147	0.0218	0.0324	0.0289	0.0503	0.0479	0.0294	0.0503	0.0479	0.0343	0.0688	0.0664
	Other_Emotions	0.0352	0.0118	0.0231	0.0298	0.0340	0.0671	0.0652	0.0337	0.0671	0.0652	0.0355	0.0686	0.0664
	Personal	0.0369	0.0130	0.0223	0.0338	0.0314	0.0591	0.0554	0.0312	0.0591	0.0554	0.0349	0.0685	0.0662
	Pet	0.0384	0.0111	0.0226	0.0285	0.0358	0.0685	0.0666	0.0350	0.0685	0.0666	0.0357	0.0687	0.0666
	Positive_Emotions	0.0370	0.0124	0.0230	0.0322	0.0341	0.0686	0.0661	0.0339	0.0686	0.0661	0.0350	0.0687	0.0664
	Social	0.0381	0.0117	0.0226	0.0347	0.0328	0.0668	0.0647	0.0321	0.0668	0.0647	0.0353	0.0685	0.0663
NDCG	ALL	0.0559	0.0085	0.0076	0.0471	0.0432	0.0837	0.0797	0.0434	0.0837	0.0797	0.0497	0.0947	0.0912
	Emotions	0.0532	0.0200	0.0316	0.0473	0.0447	0.0837	0.0795	0.0451	0.0837	0.0795	0.0500	0.0951	0.0916
	Environmental	0.0554	0.0190	0.0323	0.0433	0.0495	0.0941	0.0901	0.0507	0.0941	0.0901	0.0508	0.0953	0.0916
	Family	0.0545	0.0183	0.0333	0.0459	0.0470	0.0927	0.0892	0.0465	0.0927	0.0892	0.0500	0.0954	0.0919
	Friendship	0.0564	0.0207	0.0337	0.0440	0.0498	0.0947	0.0915	0.0490	0.0947	0.0915	0.0513	0.0956	0.0923
	Interpersonal_Relationship	0.0555	0.0195	0.0331	0.0481	0.0435	0.0937	0.0899	0.0447	0.0937	0.0899	0.0519	0.0952	0.0918
	Mood	0.0547	0.0181	0.0333	0.0422	0.0516	0.0952	0.0917	0.0513	0.0952	0.0917	0.0515	0.0958	0.0924
	Negative_Emotions	0.0552	0.0217	0.0315	0.0462	0.0420	0.0745	0.0718	0.0427	0.0745	0.0718	0.0498	0.0956	0.0921
	Other_Emotions	0.0512	0.0182	0.0333	0.0434	0.0483	0.0932	0.0902	0.0481	0.0932	0.0902	0.0511	0.0954	0.0920
	Personal	0.0531	0.0196	0.0326	0.0485	0.0451	0.0840	0.0797	0.0449	0.0840	0.0797	0.0501	0.0951	0.0916
	Pet	0.0550	0.0174	0.0328	0.0411	0.0513	0.0953	0.0924	0.0498	0.0953	0.0924	0.0512	0.0956	0.0924
	Positive_Emotions	0.0537	0.0188	0.0332	0.0462	0.0487	0.0953	0.0915	0.0482	0.0953	0.0915	0.0506	0.0955	0.0921
Social	0.0546	0.0176	0.0330	0.0489	0.0465	0.0930	0.0899	0.0458	0.0930	0.0899	0.0507	0.0951	0.0917	
AUC	ALL	0.5550	0.5094	0.5080	0.5449	0.5426	0.5819	0.5789	0.5430	0.5819	0.5789	0.5487	0.5900	0.5864
	Emotions	0.5533	0.5208	0.5317	0.5471	0.5442	0.5826	0.5794	0.5447	0.5826	0.5794	0.5493	0.5910	0.5872
	Environmental	0.5543	0.5201	0.5323	0.5427	0.5489	0.5891	0.5855	0.5501	0.5891	0.5855	0.5502	0.5913	0.5876
	Family	0.5543	0.5194	0.5331	0.5451	0.5466	0.5893	0.5859	0.5460	0.5893	0.5859	0.5492	0.5914	0.5878
	Friendship	0.5558	0.5217	0.5340	0.5442	0.5487	0.5907	0.5875	0.5481	0.5907	0.5875	0.5513	0.5919	0.5886
	Interpersonal_Relationship	0.5545	0.5203	0.5328	0.5469	0.5437	0.5894	0.5860	0.5449	0.5894	0.5860	0.5510	0.5910	0.5874
	Mood	0.5545	0.5196	0.5330	0.5420	0.5514	0.5917	0.5884	0.5512	0.5917	0.5884	0.5512	0.5923	0.5889
	Negative_Emotions	0.5558	0.5224	0.5315	0.5456	0.5425	0.5774	0.5757	0.5430	0.5774	0.5757	0.5501	0.5919	0.5886

Other_Emotions	0.5516	0.5197	0.5333	0.5439	0.5474	0.5895	0.5861	0.5475	0.5895	0.5861	0.5509	0.5917	0.5878
Personal	0.5526	0.5206	0.5330	0.5479	0.5445	0.5827	0.5795	0.5444	0.5827	0.5795	0.5495	0.5910	0.5872
Pet	0.5545	0.5192	0.5331	0.5413	0.5509	0.5919	0.5888	0.5493	0.5919	0.5888	0.5510	0.5921	0.5888
Positive_Emotions	0.5540	0.5200	0.5332	0.5458	0.5480	0.5916	0.5876	0.5473	0.5916	0.5876	0.5506	0.5917	0.5881
Social	0.5537	0.5183	0.5334	0.5473	0.5453	0.5890	0.5859	0.5450	0.5890	0.5859	0.5501	0.5908	0.5871

Tabla 18: Métricas de evaluación extendida sobre dataset Yelp Hotels

Yelp Beauty Spas - CAMF_C			
ALL	Personal	Social	Environmental

	Damerau-			Damerau-			Damerau-			Damerau-			
	Levenshtein	Levenshtein	Jaro-Winkler	Levenshtein	Levenshtein	Jaro-Winkler	Levenshtein	Levenshtein	Jaro-Winkler	Levenshtein	Levenshtein	Jaro-Winkler	
MAE	0.5	0.9352	0.9347	0.9487	0.9469	0.9465	0.9460	0.9720	0.9723	0.9699	0.9703	0.9734	0.9710
	0.6	0.9448	0.9479	0.9481	0.9463	0.9448	0.9451	0.9738	0.9742	0.9701	0.9727	0.9733	0.9717
	0.7	0.9440	0.9452	0.9386	0.9464	0.9515	0.9420	0.9755	0.9754	0.9662	0.9752	0.9726	0.9700
	0.8	0.9400	0.9420	0.9442	0.9527	0.9458	0.9431	0.9723	0.9720	0.9670	0.9744	0.9715	0.9730
	0.9	0.9424	0.9435	0.9392	0.9475	0.9475	0.9418	0.9738	0.9743	0.9720	0.9738	0.9702	0.9690
	1.0	0.9443	0.9443	0.9443	0.9495	0.9495	0.9495	0.9745	0.9745	0.9745	0.9716	0.9716	0.9716
RMSE	0.5	1.2245	1.2232	1.2231	1.2289	1.2285	1.2312	1.2522	1.2535	1.2485	1.2575	1.2596	1.2584
	0.6	1.2259	1.2261	1.2216	1.2272	1.2264	1.2296	1.2520	1.2536	1.2473	1.2569	1.2573	1.2576
	0.7	1.2256	1.2306	1.2136	1.2270	1.2349	1.2255	1.2534	1.2538	1.2460	1.2590	1.2565	1.2578
	0.8	1.2250	1.2248	1.2189	1.2321	1.2248	1.2270	1.2511	1.2517	1.2454	1.2583	1.2574	1.2580
	0.9	1.2248	1.2229	1.2213	1.2268	1.2251	1.2250	1.2513	1.2533	1.2509	1.2576	1.2577	1.2557
	1.0	1.2277	1.2277	1.2277	1.2294	1.2294	1.2294	1.2535	1.2535	1.2535	1.2580	1.2580	1.2580
Pre@5	0.5	0.0029	0.0030	0.0029	0.0029	0.0030	0.0031	0.0033	0.0034	0.0032	0.0037	0.0037	0.0037
	0.6	0.0030	0.0031	0.0030	0.0034	0.0031	0.0029	0.0035	0.0036	0.0035	0.0035	0.0037	0.0037
	0.7	0.0030	0.0029	0.0032	0.0029	0.0032	0.0032	0.0035	0.0033	0.0033	0.0038	0.0037	0.0035
	0.8	0.0030	0.0029	0.0030	0.0032	0.0032	0.0032	0.0035	0.0035	0.0033	0.0037	0.0038	0.0037
	0.9	0.0030	0.0029	0.0031	0.0029	0.0030	0.0031	0.0035	0.0034	0.0033	0.0036	0.0038	0.0036
	1.0	0.0031	0.0031	0.0031	0.0031	0.0031	0.0031	0.0035	0.0035	0.0035	0.0037	0.0037	0.0037
Pre@10	0.5	0.0025	0.0026	0.0026	0.0025	0.0025	0.0027	0.0027	0.0029	0.0026	0.0030	0.0029	0.0030
	0.6	0.0026	0.0027	0.0025	0.0027	0.0026	0.0025	0.0028	0.0029	0.0028	0.0029	0.0030	0.0030
	0.7	0.0025	0.0025	0.0027	0.0025	0.0026	0.0026	0.0028	0.0028	0.0027	0.0031	0.0030	0.0029
	0.8	0.0025	0.0025	0.0025	0.0026	0.0025	0.0027	0.0029	0.0029	0.0028	0.0030	0.0030	0.0030
	0.9	0.0026	0.0025	0.0025	0.0025	0.0025	0.0027	0.0028	0.0028	0.0028	0.0030	0.0030	0.0029
	1.0	0.0027	0.0027	0.0027	0.0026	0.0026	0.0026	0.0028	0.0028	0.0028	0.0030	0.0030	0.0030
Rec@5	0.5	0.0145	0.0150	0.0146	0.0145	0.0148	0.0154	0.0159	0.0164	0.0155	0.0171	0.0173	0.0173
	0.6	0.0149	0.0153	0.0147	0.0166	0.0150	0.0142	0.0167	0.0174	0.0168	0.0162	0.0170	0.0172

	0.7	0.0147	0.0142	0.0157	0.0141	0.0156	0.0159	0.0169	0.0160	0.0160	0.0177	0.0172	0.0165
	0.8	0.0147	0.0144	0.0150	0.0155	0.0155	0.0156	0.0169	0.0167	0.0163	0.0172	0.0176	0.0172
	0.9	0.0146	0.0143	0.0152	0.0144	0.0146	0.0155	0.0168	0.0165	0.0159	0.0171	0.0180	0.0166
	1.0	0.0151	0.0151	0.0151	0.0153	0.0153	0.0153	0.0166	0.0166	0.0166	0.0171	0.0171	0.0171
Rec@10	0.5	0.0249	0.0256	0.0254	0.0244	0.0249	0.0267	0.0264	0.0275	0.0257	0.0281	0.0274	0.0282
	0.6	0.0255	0.0263	0.0252	0.0263	0.0260	0.0246	0.0274	0.0277	0.0273	0.0267	0.0283	0.0279
	0.7	0.0246	0.0246	0.0266	0.0244	0.0256	0.0257	0.0272	0.0264	0.0263	0.0285	0.0277	0.0271
	0.8	0.0249	0.0241	0.0251	0.0252	0.0244	0.0262	0.0278	0.0277	0.0270	0.0279	0.0281	0.0280
	0.9	0.0252	0.0242	0.0251	0.0243	0.0243	0.0262	0.0270	0.0271	0.0268	0.0277	0.0284	0.0270
	1.0	0.0261	0.0261	0.0261	0.0249	0.0249	0.0249	0.0272	0.0272	0.0272	0.0280	0.0280	0.0280
MAP	0.5	0.0086	0.0086	0.0084	0.0084	0.0087	0.0092	0.0098	0.0099	0.0092	0.0107	0.0106	0.0108
	0.6	0.0089	0.0089	0.0085	0.0099	0.0088	0.0081	0.0097	0.0101	0.0099	0.0101	0.0106	0.0106
	0.7	0.0084	0.0080	0.0093	0.0085	0.0091	0.0095	0.0096	0.0096	0.0095	0.0110	0.0105	0.0099
	0.8	0.0083	0.0085	0.0086	0.0089	0.0090	0.0094	0.0104	0.0099	0.0093	0.0100	0.0104	0.0106
	0.9	0.0085	0.0083	0.0086	0.0084	0.0085	0.0091	0.0098	0.0096	0.0095	0.0106	0.0112	0.0102
	1.0	0.0090	0.0090	0.0090	0.0093	0.0093	0.0093	0.0100	0.0100	0.0100	0.0105	0.0105	0.0105
NDCG	0.5	0.0124	0.0126	0.0124	0.0121	0.0125	0.0132	0.0138	0.0141	0.0131	0.0150	0.0147	0.0150
	0.6	0.0127	0.0130	0.0124	0.0137	0.0128	0.0119	0.0139	0.0143	0.0140	0.0141	0.0149	0.0148
	0.7	0.0122	0.0119	0.0133	0.0122	0.0130	0.0133	0.0138	0.0136	0.0135	0.0153	0.0147	0.0140
	0.8	0.0122	0.0122	0.0124	0.0128	0.0127	0.0133	0.0146	0.0141	0.0134	0.0144	0.0147	0.0148
	0.9	0.0124	0.0120	0.0125	0.0122	0.0122	0.0131	0.0139	0.0138	0.0136	0.0147	0.0154	0.0143
	1.0	0.0130	0.0130	0.0130	0.0130	0.0130	0.0130	0.0141	0.0141	0.0141	0.0147	0.0147	0.0147
AUC	0.5	0.5125	0.5128	0.5126	0.5123	0.5126	0.5134	0.5135	0.5141	0.5131	0.5148	0.5145	0.5148
	0.6	0.5128	0.5132	0.5125	0.5133	0.5131	0.5123	0.5140	0.5143	0.5138	0.5141	0.5150	0.5147
	0.7	0.5124	0.5123	0.5133	0.5123	0.5130	0.5129	0.5140	0.5136	0.5133	0.5150	0.5147	0.5141
	0.8	0.5125	0.5121	0.5125	0.5128	0.5124	0.5132	0.5143	0.5142	0.5137	0.5147	0.5148	0.5146
	0.9	0.5127	0.5121	0.5126	0.5123	0.5123	0.5131	0.5139	0.5139	0.5137	0.5146	0.5151	0.5143
	1.0	0.5131	0.5131	0.5131	0.5126	0.5126	0.5126	0.5140	0.5140	0.5140	0.5147	0.5147	0.5147

Tabla 19: Métricas de evaluación extendida sobre dataset Yelp Beauty Spas – CAMF_C

		Yelp Beauty Spas - UserSplitting-ItemKNN											
		ALL			Personal			Social			Environmental		
		Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler
		n	n		n	n		n	n		n	n	
MAE	0.5	1.0332	1.0332	1.0330	1.0332	1.0332	1.0328	1.0334	1.0334	1.0332	1.0330	1.0330	1.0330
	0.6	1.0334	1.0334	1.0332	1.0334	1.0334	1.0330	1.0330	1.0330	1.0334	1.0330	1.0330	1.0330
	0.7	1.0335	1.0333	1.0330	1.0335	1.0330	1.0328	1.0334	1.0334	1.0333	1.0330	1.0330	1.0330
	0.8	1.0330	1.0334	1.0335	1.0330	1.0334	1.0332	1.0330	1.0330	1.0336	1.0330	1.0330	1.0330
	0.9	1.0332	1.0335	1.0331	1.0332	1.0335	1.0329	1.0334	1.0330	1.0334	1.0330	1.0330	1.0330
	1.0	1.0334	1.0334	1.0334	1.0330	1.0330	1.0330	1.0335	1.0335	1.0335	1.0330	1.0330	1.0330
RMSE	0.5	1.3276	1.3276	1.3275	1.3276	1.3276	1.3274	1.3277	1.3277	1.3276	1.3275	1.3275	1.3275
	0.6	1.3276	1.3276	1.3276	1.3276	1.3276	1.3275	1.3275	1.3275	1.3276	1.3275	1.3275	1.3275
	0.7	1.3277	1.3276	1.3275	1.3277	1.3275	1.3274	1.3277	1.3277	1.3276	1.3275	1.3275	1.3275
	0.8	1.3275	1.3277	1.3277	1.3275	1.3277	1.3276	1.3275	1.3275	1.3278	1.3275	1.3275	1.3275
	0.9	1.3276	1.3277	1.3276	1.3276	1.3277	1.3275	1.3277	1.3275	1.3277	1.3275	1.3275	1.3275
	1.0	1.3277	1.3277	1.3277	1.3275	1.3275	1.3275	1.3278	1.3278	1.3278	1.3275	1.3275	1.3275
Pre@5	0.5	0.0033	0.0033	0.0034	0.0034	0.0034	0.0034	0.0035	0.0035	0.0036	0.0038	0.0038	0.0037
	0.6	0.0034	0.0034	0.0033	0.0035	0.0035	0.0034	0.0036	0.0036	0.0035	0.0038	0.0038	0.0037
	0.7	0.0033	0.0033	0.0034	0.0035	0.0035	0.0034	0.0035	0.0035	0.0035	0.0038	0.0038	0.0037
	0.8	0.0034	0.0033	0.0033	0.0035	0.0034	0.0034	0.0036	0.0036	0.0035	0.0038	0.0038	0.0037
	0.9	0.0033	0.0033	0.0032	0.0035	0.0035	0.0034	0.0035	0.0036	0.0035	0.0038	0.0038	0.0038
	1.0	0.0032	0.0032	0.0032	0.0035	0.0035	0.0035	0.0034	0.0034	0.0034	0.0038	0.0038	0.0038

Pre@10	0.5	0.0055	0.0055	0.0055	0.0055	0.0055	0.0055	0.0055	0.0055	0.0056	0.0056	0.0056	0.0059	0.0059	0.0058
	0.6	0.0055	0.0055	0.0054	0.0055	0.0055	0.0055	0.0057	0.0057	0.0056	0.0056	0.0056	0.0059	0.0059	0.0058
	0.7	0.0055	0.0054	0.0055	0.0055	0.0055	0.0055	0.0056	0.0056	0.0056	0.0056	0.0056	0.0059	0.0059	0.0058
	0.8	0.0055	0.0054	0.0054	0.0055	0.0055	0.0055	0.0057	0.0057	0.0056	0.0056	0.0056	0.0059	0.0059	0.0058
	0.9	0.0055	0.0055	0.0054	0.0055	0.0055	0.0055	0.0056	0.0057	0.0056	0.0056	0.0056	0.0059	0.0059	0.0059
	1.0	0.0054	0.0054	0.0054	0.0055	0.0055	0.0055	0.0056	0.0056	0.0056	0.0056	0.0056	0.0059	0.0059	0.0059
Rec@5	0.5	0.0160	0.0160	0.0168	0.0164	0.0164	0.0166	0.0160	0.0160	0.0171	0.0167	0.0167	0.0167	0.0167	0.0166
	0.6	0.0165	0.0165	0.0163	0.0166	0.0166	0.0163	0.0166	0.0166	0.0166	0.0166	0.0166	0.0167	0.0167	0.0164
	0.7	0.0161	0.0158	0.0165	0.0165	0.0166	0.0166	0.0160	0.0160	0.0170	0.0160	0.0160	0.0167	0.0167	0.0166
	0.8	0.0164	0.0160	0.0163	0.0166	0.0162	0.0167	0.0166	0.0166	0.0167	0.0166	0.0166	0.0167	0.0165	0.0164
	0.9	0.0160	0.0163	0.0157	0.0164	0.0164	0.0164	0.0160	0.0165	0.0160	0.0160	0.0160	0.0167	0.0167	0.0165
	1.0	0.0156	0.0156	0.0156	0.0166	0.0166	0.0166	0.0158	0.0158	0.0158	0.0158	0.0158	0.0167	0.0167	0.0167
Rec@10	0.5	0.0540	0.0540	0.0542	0.0540	0.0540	0.0541	0.0540	0.0540	0.0544	0.0545	0.0545	0.0545	0.0545	0.0544
	0.6	0.0541	0.0541	0.0539	0.0541	0.0541	0.0540	0.0543	0.0543	0.0543	0.0543	0.0543	0.0545	0.0545	0.0543
	0.7	0.0539	0.0538	0.0543	0.0539	0.0541	0.0541	0.0540	0.0540	0.0543	0.0543	0.0543	0.0545	0.0545	0.0544
	0.8	0.0542	0.0537	0.0541	0.0541	0.0537	0.0540	0.0543	0.0543	0.0544	0.0544	0.0544	0.0545	0.0543	0.0543
	0.9	0.0540	0.0539	0.0536	0.0540	0.0539	0.0540	0.0540	0.0543	0.0540	0.0540	0.0540	0.0545	0.0545	0.0543
	1.0	0.0536	0.0536	0.0536	0.0542	0.0542	0.0542	0.0538	0.0538	0.0538	0.0538	0.0538	0.0545	0.0545	0.0545
MAP	0.5	0.0146	0.0146	0.0150	0.0148	0.0148	0.0150	0.0145	0.0145	0.0149	0.0149	0.0149	0.0149	0.0149	0.0149
	0.6	0.0149	0.0149	0.0147	0.0150	0.0150	0.0148	0.0149	0.0149	0.0146	0.0146	0.0146	0.0149	0.0149	0.0149
	0.7	0.0146	0.0145	0.0151	0.0148	0.0150	0.0150	0.0145	0.0145	0.0149	0.0149	0.0149	0.0149	0.0149	0.0149
	0.8	0.0149	0.0147	0.0151	0.0150	0.0148	0.0150	0.0149	0.0149	0.0149	0.0149	0.0149	0.0149	0.0149	0.0149
	0.9	0.0146	0.0148	0.0145	0.0148	0.0148	0.0150	0.0145	0.0147	0.0145	0.0145	0.0145	0.0149	0.0149	0.0149
	1.0	0.0145	0.0145	0.0145	0.0150	0.0150	0.0150	0.0144	0.0144	0.0144	0.0144	0.0144	0.0149	0.0149	0.0149
NDCG	0.5	0.0234	0.0234	0.0238	0.0237	0.0237	0.0239	0.0235	0.0235	0.0239	0.0239	0.0239	0.0242	0.0242	0.0241
	0.6	0.0238	0.0238	0.0235	0.0239	0.0239	0.0236	0.0239	0.0239	0.0236	0.0236	0.0236	0.0242	0.0242	0.0241
	0.7	0.0234	0.0234	0.0239	0.0237	0.0239	0.0239	0.0235	0.0235	0.0239	0.0239	0.0239	0.0242	0.0242	0.0241
	0.8	0.0238	0.0235	0.0238	0.0239	0.0236	0.0238	0.0239	0.0240	0.0238	0.0238	0.0238	0.0242	0.0242	0.0241

	0.9	0.0235	0.0236	0.0233	0.0237	0.0237	0.0238	0.0235	0.0238	0.0235	0.0242	0.0242	0.0241
	1.0	0.0233	0.0233	0.0233	0.0239	0.0239	0.0239	0.0235	0.0235	0.0235	0.0242	0.0242	0.0242
AUC	0.5	0.5268	0.5268	0.5268	0.5271	0.5271	0.5270	0.5275	0.5275	0.5275	0.5289	0.5289	0.5286
	0.6	0.5269	0.5269	0.5267	0.5272	0.5272	0.5269	0.5278	0.5278	0.5274	0.5289	0.5289	0.5285
	0.7	0.5268	0.5268	0.5268	0.5272	0.5272	0.5270	0.5276	0.5276	0.5274	0.5290	0.5290	0.5286
	0.8	0.5269	0.5267	0.5268	0.5272	0.5270	0.5270	0.5278	0.5279	0.5274	0.5290	0.5288	0.5285
	0.9	0.5268	0.5268	0.5265	0.5272	0.5271	0.5269	0.5276	0.5279	0.5276	0.5290	0.5290	0.5287
	1.0	0.5267	0.5267	0.5267	0.5273	0.5273	0.5273	0.5276	0.5276	0.5276	0.5290	0.5290	0.5290

Tabla 20: Métricas de evaluación extendida sobre dataset Yelp Beauty Spas – UserSplitting-ItemKNN

		Yelp Hotels - CAMF_C											
		ALL			Personal			Social			Environmental		
		Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler
MAE	0.5	0.9016	0.9053	0.8885	0.9041	0.9049	0.8942	0.9072	0.9061	0.9044	0.9072	0.9080	0.9028
	0.6	0.9047	0.8925	0.8934	0.9036	0.8917	0.8956	0.9068	0.9081	0.9083	0.9063	0.9057	0.9031
	0.7	0.9000	0.8916	0.8881	0.9031	0.8920	0.8924	0.9066	0.9077	0.9053	0.9069	0.9048	0.9050
	0.8	0.8976	0.8931	0.8893	0.9018	0.8912	0.8942	0.9050	0.9070	0.9049	0.9046	0.9047	0.9045
	0.9	0.9033	0.8934	0.8876	0.9052	0.8933	0.8905	0.9071	0.9068	0.9041	0.9101	0.9053	0.9052
	1.0	0.8934	0.8934	0.8934	0.8960	0.8960	0.8960	0.9081	0.9081	0.9081	0.9062	0.9062	0.9062
RMSE	0.5	1.1440	1.1459	1.1241	1.1441	1.1455	1.1320	1.1472	1.1475	1.1408	1.1475	1.1480	1.1428
	0.6	1.1461	1.1300	1.1292	1.1440	1.1330	1.1351	1.1475	1.1488	1.1449	1.1469	1.1452	1.1455
	0.7	1.1442	1.1306	1.1219	1.1439	1.1349	1.1300	1.1487	1.1490	1.1435	1.1467	1.1455	1.1465
	0.8	1.1412	1.1328	1.1237	1.1412	1.1331	1.1310	1.1489	1.1484	1.1414	1.1454	1.1445	1.1463
	0.9	1.1466	1.1314	1.1253	1.1462	1.1343	1.1296	1.1496	1.1466	1.1457	1.1502	1.1445	1.1464
	1.0	1.1352	1.1352	1.1352	1.1380	1.1380	1.1380	1.1491	1.1491	1.1491	1.1464	1.1464	1.1464
Pre@5	0.5	0.0141	0.0144	0.0131	0.0137	0.0139	0.0127	0.0134	0.0135	0.0128	0.0135	0.0137	0.0133

	0.6	0.0138	0.0138	0.0131	0.0135	0.0126	0.0127	0.0131	0.0134	0.0125	0.0133	0.0136	0.0133
	0.7	0.0146	0.0133	0.0137	0.0137	0.0126	0.0133	0.0131	0.0131	0.0125	0.0134	0.0135	0.0139
	0.8	0.0145	0.0134	0.0135	0.0136	0.0129	0.0131	0.0137	0.0132	0.0123	0.0139	0.0133	0.0135
	0.9	0.0143	0.0132	0.0135	0.0133	0.0127	0.0132	0.0134	0.0134	0.0129	0.0136	0.0132	0.0137
	1.0	0.0134	0.0134	0.0134	0.0125	0.0125	0.0125	0.0132	0.0132	0.0132	0.0134	0.0134	0.0134
Pre@10	0.5	0.0119	0.0119	0.0112	0.0114	0.0118	0.0110	0.0112	0.0112	0.0108	0.0112	0.0112	0.0112
	0.6	0.0117	0.0115	0.0112	0.0114	0.0109	0.0107	0.0110	0.0112	0.0108	0.0112	0.0114	0.0110
	0.7	0.0122	0.0114	0.0114	0.0115	0.0106	0.0111	0.0110	0.0110	0.0107	0.0113	0.0114	0.0113
	0.8	0.0121	0.0114	0.0113	0.0112	0.0109	0.0111	0.0115	0.0112	0.0106	0.0115	0.0111	0.0114
	0.9	0.0119	0.0113	0.0116	0.0112	0.0109	0.0112	0.0111	0.0112	0.0107	0.0114	0.0110	0.0114
	1.0	0.0113	0.0113	0.0113	0.0109	0.0109	0.0109	0.0111	0.0111	0.0111	0.0112	0.0112	0.0112
Rec@5	0.5	0.0691	0.0707	0.0648	0.0662	0.0668	0.0623	0.0654	0.0659	0.0629	0.0654	0.0661	0.0642
	0.6	0.0676	0.0679	0.0652	0.0651	0.0615	0.0623	0.0639	0.0653	0.0616	0.0641	0.0658	0.0644
	0.7	0.0717	0.0655	0.0678	0.0663	0.0615	0.0654	0.0639	0.0642	0.0615	0.0647	0.0654	0.0673
	0.8	0.0712	0.0661	0.0670	0.0656	0.0628	0.0641	0.0667	0.0647	0.0607	0.0672	0.0643	0.0658
	0.9	0.0705	0.0653	0.0666	0.0639	0.0617	0.0647	0.0653	0.0654	0.0630	0.0657	0.0637	0.0666
	1.0	0.0663	0.0663	0.0663	0.0611	0.0611	0.0611	0.0647	0.0647	0.0647	0.0651	0.0651	0.0651
Rec@10	0.5	0.1169	0.1173	0.1112	0.1100	0.1135	0.1082	0.1095	0.1090	0.1061	0.1080	0.1085	0.1087
	0.6	0.1153	0.1137	0.1111	0.1100	0.1060	0.1045	0.1066	0.1091	0.1060	0.1080	0.1104	0.1066
	0.7	0.1198	0.1122	0.1135	0.1110	0.1031	0.1093	0.1071	0.1079	0.1055	0.1092	0.1104	0.1094
	0.8	0.1184	0.1124	0.1119	0.1085	0.1061	0.1093	0.1116	0.1092	0.1039	0.1112	0.1072	0.1106
	0.9	0.1169	0.1114	0.1152	0.1082	0.1066	0.1097	0.1084	0.1094	0.1050	0.1098	0.1063	0.1110
	1.0	0.1118	0.1118	0.1118	0.1060	0.1060	0.1060	0.1085	0.1085	0.1085	0.1086	0.1086	0.1086
MAP	0.5	0.0405	0.0405	0.0379	0.0387	0.0399	0.0372	0.0386	0.0383	0.0370	0.0388	0.0388	0.0388
	0.6	0.0396	0.0396	0.0380	0.0384	0.0362	0.0370	0.0374	0.0381	0.0363	0.0380	0.0391	0.0381
	0.7	0.0420	0.0387	0.0391	0.0396	0.0359	0.0383	0.0377	0.0382	0.0363	0.0389	0.0389	0.0390
	0.8	0.0418	0.0390	0.0390	0.0388	0.0368	0.0370	0.0390	0.0381	0.0361	0.0394	0.0379	0.0385
	0.9	0.0407	0.0386	0.0386	0.0379	0.0365	0.0379	0.0382	0.0388	0.0368	0.0384	0.0372	0.0393

	1.0	0.0389	0.0389	0.0389	0.0369	0.0369	0.0369	0.0381	0.0381	0.0381	0.0389	0.0389	0.0389
NDCG	0.5	0.0584	0.0585	0.0549	0.0556	0.0573	0.0538	0.0553	0.0549	0.0531	0.0552	0.0553	0.0553
	0.6	0.0573	0.0569	0.0550	0.0553	0.0526	0.0528	0.0537	0.0547	0.0526	0.0546	0.0559	0.0543
	0.7	0.0602	0.0559	0.0564	0.0565	0.0518	0.0549	0.0540	0.0546	0.0524	0.0555	0.0557	0.0557
	0.8	0.0597	0.0561	0.0559	0.0553	0.0530	0.0539	0.0561	0.0548	0.0520	0.0564	0.0542	0.0555
	0.9	0.0585	0.0555	0.0564	0.0545	0.0529	0.0547	0.0547	0.0554	0.0528	0.0553	0.0535	0.0562
	1.0	0.0559	0.0559	0.0559	0.0531	0.0531	0.0531	0.0546	0.0546	0.0546	0.0554	0.0554	0.0554
	AUC	0.5	0.5577	0.5579	0.5544	0.5552	0.5567	0.5534	0.5545	0.5543	0.5523	0.5541	0.5543
0.6		0.5569	0.5559	0.5544	0.5551	0.5525	0.5517	0.5531	0.5541	0.5523	0.5542	0.5551	0.5532
0.7		0.5591	0.5552	0.5556	0.5556	0.5513	0.5540	0.5532	0.5535	0.5520	0.5547	0.5552	0.5547
0.8		0.5585	0.5552	0.5549	0.5543	0.5526	0.5540	0.5557	0.5542	0.5512	0.5556	0.5534	0.5552
0.9		0.5577	0.5547	0.5564	0.5543	0.5529	0.5542	0.5540	0.5543	0.5520	0.5549	0.5532	0.5552
1.0		0.5550	0.5550	0.5550	0.5526	0.5526	0.5526	0.5537	0.5537	0.5537	0.5543	0.5543	0.5543

Tabla 21: Métricas de evaluación extendida sobre dataset Yelp Hotels – CAMF_C

Yelp Hotels - UserSplitting-ItemKNN													
		ALL			Personal			Social			Environmental		
		Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler	Levenshtein	Damerau-Levenshtein	Jaro-Winkler
MAE	0.5	1.0157	1.0157	1.0157	1.0157	1.0157	1.0153	1.0157	1.0157	1.0160	1.0157	1.0157	1.0157
	0.6	1.0157	1.0157	1.0157	1.0157	1.0157	1.0153	1.0157	1.0157	1.0160	1.0157	1.0157	1.0157
	0.7	1.0157	1.0157	1.0157	1.0157	1.0157	1.0153	1.0157	1.0157	1.0160	1.0157	1.0157	1.0157
	0.8	1.0157	1.0157	1.0157	1.0157	1.0157	1.0153	1.0157	1.0157	1.0160	1.0157	1.0157	1.0157
	0.9	1.0157	1.0157	1.0153	1.0157	1.0157	1.0153	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157
	1.0	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157	1.0157
RMSE	0.5	1.2335	1.2335	1.2331	1.2335	1.2335	1.2329	1.2335	1.2335	1.2337	1.2335	1.2335	1.2335
	0.6	1.2335	1.2335	1.2331	1.2335	1.2335	1.2329	1.2335	1.2335	1.2337	1.2335	1.2335	1.2335

MAP	0.5	0.0684	0.0684	0.0682	0.0687	0.0687	0.0686	0.0685	0.0685	0.0682	0.0687	0.0687	0.0686
	0.6	0.0684	0.0683	0.0682	0.0687	0.0685	0.0686	0.0685	0.0685	0.0681	0.0687	0.0686	0.0686
	0.7	0.0684	0.0683	0.0682	0.0687	0.0685	0.0686	0.0685	0.0685	0.0681	0.0687	0.0686	0.0686
	0.8	0.0684	0.0683	0.0682	0.0687	0.0685	0.0686	0.0685	0.0685	0.0682	0.0687	0.0686	0.0686
	0.9	0.0684	0.0683	0.0684	0.0687	0.0685	0.0686	0.0685	0.0685	0.0685	0.0687	0.0686	0.0686
	1.0	0.0683	0.0683	0.0683	0.0685	0.0685	0.0685	0.0685	0.0685	0.0685	0.0686	0.0686	0.0686
NDCG	0.5	0.0948	0.0948	0.0944	0.0954	0.0954	0.0951	0.0952	0.0952	0.0945	0.0954	0.0954	0.0953
	0.6	0.0949	0.0947	0.0944	0.0954	0.0951	0.0951	0.0952	0.0951	0.0945	0.0954	0.0953	0.0953
	0.7	0.0949	0.0947	0.0944	0.0954	0.0951	0.0951	0.0952	0.0951	0.0945	0.0954	0.0953	0.0953
	0.8	0.0949	0.0947	0.0944	0.0954	0.0951	0.0951	0.0952	0.0951	0.0945	0.0954	0.0953	0.0953
	0.9	0.0949	0.0947	0.0948	0.0954	0.0951	0.0951	0.0952	0.0951	0.0951	0.0954	0.0953	0.0953
	1.0	0.0947	0.0947	0.0947	0.0951	0.0951	0.0951	0.0951	0.0951	0.0951	0.0953	0.0953	0.0953
AUC	0.5	0.5903	0.5903	0.5894	0.5916	0.5916	0.5905	0.5911	0.5911	0.5900	0.5914	0.5914	0.5912
	0.6	0.5904	0.5899	0.5894	0.5916	0.5909	0.5905	0.5911	0.5908	0.5900	0.5914	0.5913	0.5912
	0.7	0.5904	0.5900	0.5894	0.5916	0.5910	0.5905	0.5911	0.5908	0.5900	0.5914	0.5913	0.5912
	0.8	0.5904	0.5900	0.5894	0.5916	0.5910	0.5906	0.5911	0.5908	0.5899	0.5914	0.5913	0.5912
	0.9	0.5904	0.5900	0.5898	0.5916	0.5910	0.5906	0.5911	0.5908	0.5907	0.5914	0.5913	0.5912
	1.0	0.5900	0.5900	0.5900	0.5910	0.5910	0.5910	0.5908	0.5908	0.5908	0.5913	0.5913	0.5913

Tabla 22: Métricas de evaluación extendida sobre dataset Yelp Hotels – UserSplitting-ItemKNN

