

**Sistema de recomendaciones soportado en un esquema de
cooperación Smart TV - Smartphone para entornos de
publicidad ubicua**



**Universidad
del Cauca**

Tesis Doctoral

MSc.Ing. Francisco Orlando Martínez Pabón

Director: PhD. Ing. Gustavo Adolfo Ramírez González

Universidad del Cauca
Facultad de Ingeniería Electronica y Telecomunicaciones
Doctorado en Ingeniería Telemática
Departamento de Telemática
Línea de Investigación en Aplicaciones sobre Internet
Popayán, Junio de 2016

*A Juan Francisco y Patricia
Motores de mi inspiración ...*

Agradecimientos

Quiero extender un agradecimiento muy especial a mi director, PhD. Gustavo Ramírez, por sus valiosos aportes y todo el apoyo brindado durante la realización de mis estudios de Doctorado. Igualmente, agradecer al Grupo de Ingeniería de Telemática, al coordinador del programa de Doctorado PhD. Álvaro Rendón y a los miembros del comité por su significativo soporte durante todo este ciclo.

En el mismo sentido, quiero expresar un agradecimiento sincero a mis tutores durante las estancias de investigación que realicé en las universidades Carlos III de Madrid y Universitat Pompeu Fabra en Barcelona, PhD. Mario Muñoz Organero y PhD. Davinia Hernández-Leo respectivamente, por darme la oportunidad de compartir experiencias y acercarme a su trabajo con cada uno de los miembros de su equipo de investigadores, lo cual generó sin dudas un enriquecimiento importante en los aportes plasmados en la presente tesis doctoral.

Igualmente, quiero expresar mi reconocimiento a Colciencias por darme la posibilidad de ser beneficiario de la *convocatoria 567 Doctorados Nacionales*, con la cual muchos estudiantes obtuvimos la financiación para llevar a cabo nuestros estudios y así tener la oportunidad de retribuir a nuestro país con conocimiento. Así mismo, mi reconocimiento a Colfuturo por su excelente gestión en la administración de los recursos de la convocatoria, y a la Vicerrectoría de investigaciones de la Universidad del Cauca quien apoyó mis estudios en la fase inicial a través de la *V Convocatoria Programa de Apoyo a Proyectos de Investigación, Desarrollo e Innovación en el marco de Maestrías y Doctorados*, con el proyecto ID VRI 3593 *SMARTA: Modelo para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone*.

Finalmente quiero expresar mi agradecimiento a mis colegas más cercanos durante este ciclo de trabajo Juan Camilo Ospina, Jaime Caicedo, Victor Garzón y Jhon Jairo Ibarra y por supuesto a mi familia, quienes finalmente fueron la razón de ser para iniciar este camino; gracias Juan Francisco y Patricia, por ser una fuente de motivación constante.

Resumen

El uso de tecnologías de computación ubicua con propósitos publicitarios, constituye un campo emergente de gran interés para grandes, medianas y pequeñas compañías. Aunque tradicionalmente los Sistemas de Recomendaciones han sido una solución para disminuir el esfuerzo cognitivo de los usuarios para encontrar ítems personalizados y de utilidad, el filtrado colaborativo clásico que frecuentemente se usa en este tipo de sistemas, necesita incluir información del contexto para ser más efectivo. Por años, el *word of mouth* ha sido una poderosa técnica con propósitos de marketing; en este sentido, la inclusión de información sobre el contexto social del usuario en el algoritmo de recomendación, específicamente la confianza en otros usuarios, puede convertirse en un mecanismo para recibir la influencia de las opiniones de individuos que hacen parte del círculo social más cercano del usuario objetivo, sobre un conjunto de anuncios específico. Al respecto, algunas aproximaciones usan métodos explícitos para inferir la confianza entre usuarios, mientras que otras han definido métodos implícitos para hacer la inferencia a partir de la propia matriz de ratings o de información de interacción disponible en redes sociales.

No obstante, no existe un consenso acerca de las variables que se deben usar durante el proceso de inferencia de confianza, y su integración en un sistema de recomendaciones clásico que usa filtrado colaborativo amerita un estudio más profundo. Por otro lado, el dominio de la publicidad ubicua demanda una evaluación del sistema de recomendaciones desde una perspectiva precisión/novedad. La mejora de este balance entre precisión y novedad, es un aspecto que no sólo está relacionado con el algoritmo de recomendación per se, sino también con una mejor estrategia de despliegue de los anuncios; por ejemplo, la mayoría de las iniciativas interactivas que involucran pantallas públicas y dispositivos móviles, no consideran aproximaciones multi-pantalla que distribuyan el contenido de forma complementaria entre los displays participantes. Por definición, las recomendaciones entregadas a un grupo de personas que observa una pantalla pública serán menos personalizadas que las recomendaciones desplegadas en el dispositivo personal de cada individuo (teléfono o tablet), pero probablemente resulten también más novedosas para los usuarios.

La presente investigación propone una original aproximación para un Sistema de Recomendaciones basado en confianza, soportado en un esquema de cooperación Smart TV - Smartphone. Con este propósito se realizaron tres estudios complementarios: en un primer estudio, el trabajo se focalizó en el diseño de un algoritmo de inferencia de confianza

entre usuarios a partir de la información disponible en un red social de uso masivo como Facebook; posteriormente, en una segunda etapa se diseñó una aproximación para adaptar un algoritmo de filtrado colaborativo clásico que incorporara dicha información de confianza al momento de generar las recomendaciones. Igualmente, se diseñó un mecanismo de cooperación Smart TV - Smartphone para soportar la entrega de recomendaciones bajo un principio precisión/novedad. Durante el desarrollo de los estudios, se plantearon pruebas online y offline con el ánimo de facilitar la comprobación de las hipótesis.

Específicamente, las contribuciones de la presente investigación se pueden resumir de la siguiente manera: i) un algoritmo para inferir confianza a partir de la información disponible en la red social Facebook; ii) la adaptación de un algoritmo de filtrado colaborativo clásico para incluir el componente de confianza; iii) un esquema de cooperación Smart TV - Smartphone que soporta la entrega de recomendaciones bajo una aproximación multi-pantalla, con el ánimo de mejorar el balance precisión/novedad percibido por los usuarios; iv) un método de referencia para evaluar el sistema de recomendaciones desde una perspectiva precisión/novedad.

Finalmente, a partir de los resultados obtenidos se pueden evidenciar dos importantes conclusiones: la inclusión de información de confianza en el algoritmo de filtrado colaborativo, puede ocasionar un detrimiento en la precisión pero a costa de una mejora en la novedad de las recomendaciones; en el mismo sentido, el soporte que ofrece un esquema multipantalla para el despliegue de los anuncios, mejora igualmente el balance entre la precisión y la novedad percibida por los usuarios, lo cual evidencia que un mejor comportamiento del sistema de recomendaciones no sólo depende de la mejora de los algoritmos per-se como lo han planteado otras investigaciones, sino también de una adecuada estrategia de despliegue. Algunas limitaciones relacionadas con el manejo de la naturaleza ad-hoc en la conformación de los grupos en escenarios digital-signage, lo cual dificulta la extracción de la información desde la red social para la inferencia de confianza, o la mejora en los esquemas de seguridad del middleware Smart TV - Smartphone y su extensión a otras plataformas constituyen tópicos de interés para trabajos futuros.

Palabras clave: *Sistemas de recomendaciones, Inferencia de confianza, Filtrado colaborativo, Middleware Smart TV - Smartphone, Precisión/novedad.*

Abstract

The use of pervasive computing technologies for advertising purposes is an interesting emergent field for large, medium and small companies. Although recommender systems have been a traditional solution to decrease users' cognitive effort to find good and personalized items, the classic collaborative filtering needs to include contextual information to be more effective. For years, the "word of mouth" has been a powerful technique for marketing purposes; so, the inclusion of users' social context information in the recommendation algorithm, specifically trust in other users, may be a mechanism for obtaining ads' influence from other users in their closest social circle. Some approaches uses explicit methods to infer the trust between users, and others have defined implicit methods to infer trust from the ratings matrix itself or from social networks interaction information.

However, there is no consensus about the variables to use during the trust inference process, and its integration into a classic collaborative filtering recommender system deserves a deeper research. On the other hand, the pervasive advertising domain demands a recommender system evaluation from a precision/novelty perspective. The improvement of the precision/novelty balance is a matter not only related to the recommendation algorithm itself, but also a better recommendations display strategy; for example, most of public displays interaction initiatives involving mobile devices do not consider multi-screen approaches where the content is distributed between the screens in a complementary way. By definition, the recommendations for a group of people watching a public screen would be less personalized than the recommendations displayed for each individual in a personal device (e.g. Smartphone or tablet), so they could be more novel for the users.

This research proposes a novel approach for a trust based Recommender System supported on a Smart TV - Smartphone cooperation framework. Basically, three studies were done: in a first study, a trust inference algorithm between users was designed from the information of a massive used social network like Facebook; in a second phase, an approach to adapt a collaborative filtering algorithm included the trust information during the recommendations generation process. Additionally, a Smart TV - Smartphone cooperation mechanism design supported the recommendations delivery strategy under a precision/novelty principle. During the studies development, offline and online tests supported the experiments to validate the hypothesis.

Specifically, the following contributions may be highlighted for the current work: i) an algorithm to infer trust from the Facebook social network information; ii) a classic collaborative filtering algorithm adaptation to include the trust component; iii) a Smart TV - Smartphone cooperation framework to support multi-screen recommendations delivery as a method to improve the precision/novelty balance perceived by the users; iv) a reference method to evaluate the recommender system from a precision/novelty perspective.

Finally, from the results of the current work there are two important conclusions: the inclusion of trust in the collaborative filtering algorithm may affect the precision adversely but also it improves the novelty of the recommendations. On the other hand, the support of a multiscreen approach for ads delivery improves the precision/novelty balance perceived by the users; it means the improvement of the recommender system behavior not only depends on the algorithms improvements themselves (which has been the target of other researches) but also a better recommendations display and delivery strategy. Some interest topics for future works are related to the management of the ad-hoc nature during the groups conformation in digital signage environments, which makes more complex the process for extracting the information for trust inference from the social network; other topics are related to the improvement of the security framework for the Smart TV - Smartphone middleware and its extension to other platforms.

Keywords: *Recommender systems, Trust inference, Collaborative filtering, Smart TV - Smartphone middleware, Precision/novelty.*

Tabla de Contenido

	Pág.
1 Introducción	1
1.1 Contexto de investigación	1
1.2 Planteamiento del problema	4
1.3 Objetivos	6
1.4 Contribuciones	6
1.5 Publicaciones	8
1.6 Estructura del documento	9
2 Estado del arte	11
2.1 Metodología de revisión	11
2.2 Sistemas de recomendaciones para entornos de publicidad ubicua	16
2.3 Sistemas de recomendaciones basados en contexto	18
2.4 Sistemas de recomendaciones para grupos y estrategias de despliegue	21
3 Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua	25
3.1 Análisis del dominio de la publicidad ubicua	25
3.2 Arquitectura base esquema de cooperación Smart TV - Smartphone	27
3.3 Middleware de cooperación Smart TV - Smartphone	29

TABLA DE CONTENIDO

3.3.1 Requerimientos	29
3.3.2 Alcance y restricciones de implementación	30
3.3.3 Arquitectura	31
3.3.4 Modelo de comunicaciones	36
3.3.5 Modelo de interacción	36
3.3.6 Protocolo de comunicaciones	39
4 Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua	43
4.1 La confianza en entornos de publicidad ubicua	44
4.2 Inferencia de confianza a partir de las redes sociales	45
4.3 Filtrado colaborativo basado en confianza	52
4.4 Modelo de evaluación precisión/novedad	55
4.5 Recomendaciones dirigidas a grupos	57
5 Prototipo y Experimentación	63
5.1 Descripción del piloto	63
5.2 Consideraciones del dominio	68
5.3 Consideraciones sobre los datasets	69
5.4 Pruebas offline	70
5.4.1 Pruebas del sistema de recomendaciones	72
5.4.2 Pruebas del middleware Smart TV - Smartphone	74
5.4.3 Definición del MST (Maximun Sustainable Throughout)	75

TABLA DE CONTENIDO

5.4.4 Tasa efectiva de intercambio con MST	75
5.4.5 Consumo de CPU con MST	76
5.4.6 Variación del MST con varios Publishers	76
5.4.7 Variación del MST con varios Subscribers	78
5.4.8 Variación del MST con mensajes de diferente longitud	78
5.4.9 Tiempo de conexión y latencia	79
5.5 Pruebas online	80
5.5.1 Pruebas del sistema de recomendaciones	80
5.5.2 Influencia de la confianza sobre la precisión de las recomendaciones	83
5.5.3 Influencia de la confianza sobre la novedad de las recomendaciones	83
5.5.4 Influencia del esquema multi-pantalla sobre la novedad de las recomendaciones	84
5.5.5 Influencia de la técnica de agregación sobre la novedad de las recomendaciones	86
5.5.6 Pruebas del middleware Smart TV - Smartphone	87
6 Conclusiones y trabajos futuros	91
6.1 Aportes del trabajo de investigación	91
6.2 Trabajos futuros	95
6.2.1 Filtrado colaborativo basado en confianza	95
6.2.2 Middleware que soporta el modelo de cooperación Smart TV - Smartphone . . .	96
Bibliografía	97
A Publicaciones	1

TABLA DE CONTENIDO

A.1 Anexo A1	1
A.2 Anexo A2	21
A.3 Anexo A3	37
A.4 Anexo A4	41
A.5 Anexo A5	47
A.6 Anexo A6	55
A.7 Anexo A7	59
A.8 Anexo A8	77

Listado de Tablas

	Pág.
2.1 Planeación de la vigilancia tecnológica	12
3.1 Estructura objeto MotionEvent	39
3.2 Estructura de mensajes del protocolo	39
4.1 Modelo predictivo para datos de medios sociales	47
4.2 Primer conjunto de variables para inferir confianza desde Facebook	48
4.3 Resultados de la prueba de ground truth para el algoritmo de inferencia de confianza	51
4.4 Fases en el proceso de recomendación grupal	59
4.5 Técnicas de agregación para recomendaciones grupales	60
4.6 Técnica de agregación Additive	61
4.7 Técnica de agregación Least Misery	61
4.8 Técnica de agregación Most Pleasure	62
5.1 Contribución de los componentes de similitud y confianza para los diferentes tests	72
5.2 Resultados de novedad para el sistema de recomendaciones incluyendo el componente de confianza	73
5.3 Pruebas offline middleware - características HW	74
5.4 Tiempos de conexión y latencia media	79

LISTADO DE TABLAS

5.5 Nivel de novedad percibido técnicas de agregación	81
5.6 Nivel de novedad percibido prueba de hipótesis para las técnicas de agregación	81
5.7 Nivel de satisfacción percibido técnicas de agregación	82
5.8 Nivel de satisfacción percibido prueba de hipótesis para las técnicas de agregación	82
5.9 Configuración de las sesiones para los tests online	82
5.10 Mapeo entre las acciones del usuario y la escala del sistema de recomendaciones	83
5.11 Encuesta para capturar la percepción de los usuarios durante la sesión interactiva	83
5.12 Influencia de la confianza sobre la novedad en las recomendaciones	84
5.13 Influencia del esquema multi-pantalla sobre la novedad en las recomendaciones	85
5.14 Influencia de la técnica de agregación sobre la novedad en las recomendaciones	87

Listado de Figuras

	Pág.
2.1 Fases vigilancia tecnológica	12
2.2 Autores más relevantes	13
2.3 Papers más citados	14
2.4 Revistas y conferencias más relevantes	15
2.5 Estado actual del conocimiento	16
3.1 Arquitectura base esquema de cooperación Smart TV - Smartphone	28
3.2 Arquitectura del middleware	32
3.3 Middleware API	35
3.4 Modelo de comunicaciones Publisher/Subscriber para el middleware	36
3.5 Modelo de interacción para el middleware	37
3.6 Modelo de interacción - intercambio de información	38
3.7 Protocolo de comunicación - encapsulamiento	40
3.8 Representación JSON para el gesto Swipe	41
4.1 Estado del arte: inferencia de confianza a partir de las interacciones entre usuarios	46
4.2 Interacción de usuarios en una red social	48
4.3 Validación del conjunto de variables para inferencia de confianza	50
4.4 Cálculo de porcentaje de precisión del algoritmo de inferencia	51

LISTADO DE FIGURAS

4.5 Inclusión de confianza en el algoritmo de recomendación	54
4.6 Principios básicos del modelo de novedad	56
4.7 Componentes del sistema de recomendaciones	58
5.1 Cartelera electrónica de anuncios	65
5.2 Arquitectura del piloto	66
5.3 Recomendaciones de anuncios para un perfil grupal	66
5.4 Recomendaciones de anuncios para un perfil individual	67
5.5 Control tipo pad con fines interactivos y posteo de anuncios	68
5.6 Grafo de confianza para el grupo de prueba	70
5.7 Grafo de interacción social en Facebook Fundación Innovagen	71
5.8 Resultados de precisión del sistema de recomendaciones para diferentes contribuciones confianza-similitud	73
5.9 Arquitectura de pruebas para el middleware - tests offline	74
5.10 Comparación de las tasas de envío y recepción de mensajes	75
5.11 Tasa de recepción del Subscriber con MST	76
5.12 Consumo de CPU con MST	77
5.13 Variación del MST con varios Publishers	77
5.14 Variación del MST con varios Subscribers	78
5.15 Variación del MST con mensajes de diferente longitud	79
5.16 Diferencia en los valores de precisión entre las sesiones de prueba	84
5.17 Número de casos donde la novedad de las recomendaciones grupales es mayor	85

LISTADO DE FIGURAS

5.18 Percepción de novedad de los usuarios cuando se incluye el componente de confianza	86
5.19 Percepción de novedad de los usuarios por técnica de agregación	87
5.20 Novedad por técnica de agregación (Valor novedad recomendaciones grupales >Valor novedad recomendaciones individuales)	88
5.21 Consumo de CPU - Prueba online	88
5.22 Consumo de RAM - Prueba online	89

Capítulo 1

Introducción

Este capítulo describe de manera general el contexto y el problema de investigación abordado por la presente tesis doctoral. En este sentido, inicialmente se abordan los principales planteamientos que motivaron el desarrollo del presente trabajo, para luego abordar el problema identificado y las principales hipótesis que guiaron su desarrollo. Finalmente se abordan los objetivos planteados, las principales contribuciones de la presente investigación y se realiza un resumen de las publicaciones generadas en eventos y revistas especializadas.

1.1. Contexto de investigación

Sin lugar a dudas, la publicidad juega un papel importante como motor del comercio moderno en cualquiera de sus modalidades, al punto que grandes compañías como Google impulsan gran parte de sus ingresos a partir de contenido publicitario [1], [2]. Específicamente, la publicidad se enmarca en el contexto de la promoción, una de las áreas del marketing y se define en términos generales como un proceso de comunicación masivo diseñado para cambiar la actitud y el comportamiento de los receptores . Al respecto, Kotler y Keller elaboraron una definición que conceptúa la publicidad como “cualquier forma remunerada de presentación y promoción de ideas, bienes o servicios por parte de un auspiciante identificado” [3].

Recientemente, la publicidad ubicua se abre paso como un nuevo paradigma en el esquema de la publicidad tradicional y se define en términos simples como el uso de tecnologías de computación ubicua con fines publicitarios [4]. El concepto de computación ubicua se remonta a principios de los noventa cuando Marc Weiser concluye que “las tecnologías más profundas son aquellas que desaparecen. Ellas se entrelazan con nuestro diario vivir hasta hacerse indistinguibles” [5]: esa es la esencia de este nuevo paradigma que marca la evolución de la computación móvil. Por su parte, [6] agrega la siguiente conceptualización: “la computación ubicua describe la tendencia según la cual los dispositivos computacionales interconectados se entrelazan con los artefactos de nuestra vida diaria. Por consiguiente, el procesamiento, los sensores, la activación y la comunicación se encuentran embebidos

en los dispositivos y ambientes, haciendo de la computación una parte integral de nuestra vida”.

De acuerdo a lo anterior, la publicidad ubicua promueve una interacción con los usuarios en un nivel más personalizado, que permite entregar información relevante en el momento y contexto adecuado [7]. En este sentido, los dispositivos móviles modernos (Smartphones) son claros candidatos para llenar los vacíos que aún enfrenta la publicidad tradicional y varios trabajos de investigación han abordado sus propuestas de publicidad ubicua con un claro soporte de las características que son inherentes a este tipo de dispositivos (disponibilidad de información de perfiles, interacción en redes sociales, sensores, localización, entre otras).

En el mismo sentido, otra corriente interesante que marca la evolución de la publicidad actual, tiene que ver con los medios masivos, la cual está dirigida a una audiencia de consumidores más amplia, que no se encuentra en su sitio de residencia o trabajo, sino en sitios públicos o simplemente en tránsito mientras se dirige a un lugar en particular. En este contexto, las pantallas publicitarias (*public displays*) han sido ampliamente aceptadas por la comunidad y pueden encontrarse en sitios cotidianos como aeropuertos, estaciones de tren o restaurantes [8]. Esta corriente, conocida como Digital Signage¹, ha merecido un foco de atención particular en los últimos años dado su gran potencial desde el punto de vista de marketing, si se tiene en cuenta que generalmente este tipo de pantallas se ubican cerca de los sitios de decisión de compra [9]. Recientemente, el modelo de “Smart TV”, entendido en términos simples como televisores o set top boxes con capacidades de cómputo conectados a la red [10], emerge como un nuevo ecosistema de pantallas conectadas y enriquecidas a través de aplicaciones, que supone una nueva dimensión para la televisión interactiva y por supuesto un gran potencial para el Digital Signage. En un escenario más ambicioso, un esquema de cooperación Smart TV – Smartphone puede potenciar las fortalezas de ambos mundos y hacer frente a los desafíos de la publicidad moderna; el naciente modelo de Smart TV no sólo es fuerte porque a diferencia de sus antecesores integra esquemas de computación y contenido distribuido (en la nube) de una forma optimizada para la televisión o el digital signage, sino porque promueve un esquema de interacción simple con dispositivos móviles. Para el propósito del presente trabajo, el término Smartphone agrupa dispositivos móviles inteligentes (teléfonos o tabletas) con fines de interacción y despliegue; aspectos ligados a usabilidad o patrones de uso para cada familia de terminales no son considerados.

Desde esta perspectiva, son muchas las oportunidades, pero también los retos que debe enfrentar la implementación de modelos de publicidad ubicua. Precisamente, el foco de la presente investigación está relacionado con uno de los principales retos a resolver: la personalización y la adaptación al contexto². En entornos de publicidad ubicua, los Sistemas

¹Término usado para referirse al despliegue de contenidos digitales a través de pantallas, frecuentemente ubicadas en sitios públicos [8]

²En ciencias de la computación, los investigadores usan el término contexto para relacionar el procesamiento de información a aspectos de las situaciones en las cuales ese procesamiento ocurre [11]

1.1. Contexto de investigación

de Recomendaciones (SR) entendidos como herramientas software y técnicas que proporcionan sugerencias sobre ítems de interés para un usuario [12], juegan un rol relevante, por cuanto son la base para empezar a construir sugerencias personalizadas y disminuir el esfuerzo cognitivo requerido por el usuario para asimilar la información y mejorar su grado de envolvimiento con las ofertas. Al respecto, tres aproximaciones de SR resultan de interés para el presente trabajo [13]: i) filtrado colaborativo, la cual procesa correlaciones entre usuarios para reconocer su afinidad y asociar sus evaluaciones sobre los ítems; ii) filtrado basado en contenido, el cual usa las preferencias del usuario actual y predice ratings para los ítems, con base en su grado de similitud con otros que se han evaluado en el pasado; iii) filtrado basado en confianza, el cual es una variante que enriquece el filtrado colaborativo al realizar recomendaciones de acuerdo a las preferencias del círculo social cercano del individuo objetivo; esta información hace parte del contexto del usuario de acuerdo a la taxonomía presentada en [14].

No obstante, en entornos de digital signage los sistemas de recomendaciones enfrentan nuevos desafíos, si se tiene en cuenta que las recomendaciones más que a usuarios individuales, deben ir dirigidas a grupos de usuarios [15]. Aunque en principio esta característica demanda la existencia de técnicas que permitan ofrecer recomendaciones grupales a partir de preferencias individuales, la presente propuesta explora una posibilidad aún más interesante: la capacidad de mejorar la satisfacción del usuario que se encuentra observando la pantalla tanto a nivel de precisión como a nivel de novedad, no sólo a través de la mejora de los algoritmos per se, sino también a través de una mejor estrategia de despliegue y entrega de las recomendaciones.

De acuerdo a lo anterior, el contexto de investigación de la presente propuesta puede resumirse a través del siguiente escenario: Ana y Juan caminan por los pasillos de un centro comercial y deciden observar una gran pantalla que exhibe anuncios publicitarios sobre las diferentes ofertas disponibles en las tiendas. El sistema entonces detecta la presencia de estos dos usuarios y trata de calcular anuncios que se ajusten más o menos a sus preferencias. Minutos después tres personas más se acercan para observar y el sistema recalcula las recomendaciones efectuadas, lo cual puede afectar el grado de satisfacción inicial de Ana y Juan; en ese momento, cada uno de los usuarios toma su Smartphone del bolsillo y observa en la pantalla de sus dispositivo móvil recomendaciones más ajustadas a su perfil individual, sugerencias que además han sido calculadas con base en las opiniones de sus amigos más cercanos de acuerdo a la información inferida desde una red social. Este hecho tiene un impacto importante desde el punto de vista publicitario, teniendo en cuenta que el 67 % de las decisiones de compra están influenciadas por las opiniones de personas cercanas (*word of mouth*). Adicionalmente, Ana y Juan observan en su teléfono una invitación para participar en un emotivo juego: *califica los anuncios en la pantalla principal y obtén un 20 % de descuento en las tiendas durante las siguientes dos horas*. Así, Ana y Juan usan sus teléfonos para lanzar hacia la pantalla pública (usando las capacidades del acelerómetro, por ejemplo) *tomates* o *corazones* de acuerdo a su aprobación o desaprobación con respecto al anuncio que se está exhibiendo, haciendo de la publicidad una experiencia más interactiva.

1.2. Planteamiento del problema

En términos generales, la publicidad juega un papel trascendental en la supervivencia de grandes, medianas y pequeñas empresas. Por esta razón, las compañías buscan constantemente las mejores estrategias para promocionar sus productos y/o servicios, en aras de encontrar los segmentos de la población que puedan estar interesados en ellos. En este sentido, las empresas promueven sus campañas a través de diferentes medios como la televisión, periódicos, radio o Internet, tratando de encontrar los más adecuados para el mercado objetivo dentro de sus restricciones presupuestales. Pese a las nuevas oportunidades que encuentra la publicidad moderna a través de la evolución de medios tradicionales y masivos como la televisión o Internet, aún el talón de Aquiles sigue siendo la ausencia de contenidos suficientemente personalizados y ajustados a las preferencias de los usuarios; por naturaleza, la publicidad ha tenido una filosofía “broadcast” (sin distinción de público), especialmente en escenarios de digital signage [16]. La publicidad ubicua ofrece un nuevo paradigma que promete transformar los esquemas de publicidad tradicionales, pero enfrenta una serie de retos que serán analizados de acuerdo a las brechas identificadas en la construcción del estado actual del conocimiento (capítulo 2), alrededor de tres ejes de investigación: personalización, interactividad y persuasión.

Los sistemas de recomendaciones son una herramienta útil para buscar recomendaciones personalizadas. No obstante, los SR tradicionales usan aproximaciones colaborativas, basadas en contenido o híbridas en un espacio de trabajo *Usuario x Item*. La publicidad ubicua, requiere la extensión de este espacio a uno más amplio que involucre el contexto del usuario (*Usuario x Item x Contexto*). Aunque la información contextual puede ser bastante amplia, particularmente para los entornos publicitarios es de especial interés el círculo social del usuario. Las técnicas de filtrado colaborativo, generan recomendaciones a partir de las opiniones de usuarios anónimos, pero la inferencia del grado de confianza entre usuarios al momento de generar la recomendación tiene un alto impacto en el campo publicitario dada la influencia de las personas del círculo social cercano en las decisiones de compra. Sin embargo, muchas aproximaciones infieren un valor de confianza a partir de la información de la matriz de ratings, lo cual no garantiza con exactitud la inclusión de usuarios de un círculo social cercano y aquellas aproximaciones que incluyen redes de confianza, usualmente usan esquemas propietarios a partir de redes sociales construidas para tal fin.

De otro lado, la personalización en escenarios de digital signage añade una connotación grupal al conjunto de recomendaciones, con el objeto de adaptarse a las preferencias de un grupo de individuos que observa la pantalla en un momento específico. En este sentido, diversas estrategias han sido diseñadas en varios dominios de aplicación, orientadas principalmente al diseño de perfiles grupales o al cómputo de recomendaciones grupales a partir de preferencias individuales. No obstante, no se ha profundizado en la posibilidad de enriquecer la experiencia de un grupo de usuarios a través de una mejor estrategia de despliegue y entrega de las recomendaciones, que además considere la influencia de variables contextuales como el grado de confianza con usuarios de su círculo social cercano como fue

1.2. Planteamiento del problema

planteado anteriormente.

De igual manera, en entornos de publicidad ubicua es importante fijar los límites de la personalización con fines de persuasión³; ésta una de las características más importantes de la publicidad en general. Tradicionalmente, la precisión de las recomendaciones ha sido el foco de evaluación de los SR en otros dominios, pero un balance entre la precisión y la novedad en la recomendación es una característica deseable en la publicidad, con el objeto de mantener el grado de persuasión. Aunque se han abordado algunas aproximaciones para evaluar el nivel de novedad en un SR, aún no se ha explorado una aproximación concreta para entornos de publicidad ubicua.

Finalmente, el fortalecimiento de las técnicas empleadas para generar las recomendaciones en el SR es sólo una parte de la solución, pero no es suficiente para los entornos de publicidad ubicua. Específicamente en escenarios de digital signage, la búsqueda de experiencias, más que el despliegue estático de información es un valor agregado importante [18]. En este contexto, un modelo de cooperación⁴ Smart TV – Smartphone que soporte al sistema de recomendaciones, luce como un claro candidato para enriquecer este tipo de escenarios a través de experiencias más interactivas para los usuarios de la publicidad usando sus dispositivos móviles y más enriquecedoras a través del uso de una aproximación multi-pantalla. En este contexto, la mayoría de aproximaciones han centrado sus esfuerzos en esquemas de interacción con pantallas públicas usando dispositivos móviles con tecnologías de corto alcance como NFC o Bluetooth, pero la incorporación de modelos basados en Smart TV es incipiente y más aún considerando escenarios multi-screen, que pueden generar un impacto positivo en el despliegue y la interacción de los usuarios con las ofertas publicitarias.

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

¿Cómo construir un sistema de recomendaciones para entornos de publicidad ubicua soportado en un esquema de colaboración Smart TV – Smartphone?

En el mismo sentido, se plantean las siguientes hipótesis como referentes a desarrollar en la presente tesis doctoral y que serán retomadas más adelante:

H1: la inclusión de esquemas de cooperación multipantalla para la entrega de recomendaciones mejoran el balance precisión/novedad

³Tecnología de persuasión: “usar computadores para cambiar lo que pensamos y hacemos [17]

⁴Se entiende por cooperación, la capacidad de desplegar contenidos complementarios en la pantalla pública y los Smartphones, usando un protocolo de interacción específico y manteniendo un procesamiento independiente en cada dispositivo.

H2: *la inclusión de información de confianza en el algoritmo de filtrado colaborativo contribuye positivamente en el mejoramiento del balance precisión/novedad*

1.3. Objetivos

A continuación se resumen los objetivos planteados para el desarrollo de la presente tesis doctoral:

Objetivo general

Proponer un sistema de recomendaciones apoyado en un esquema de cooperación Smart TV – Smartphone para entornos de publicidad ubicua.

Objetivos específicos

- Evaluar algoritmos de filtrado colaborativo para generar recomendaciones dirigidas a perfiles individuales y grupales en un entorno publicitario.
- Adaptar un algoritmo de filtrado colaborativo para incluir información contextual del usuario a partir de su red de confianza.
- Construir un esquema de cooperación Smart TV – Smartphone que soporte la entrega de recomendaciones bajo el principio precisión/novedad en un entorno de digital signage.
- Evaluar el sistema de recomendaciones construido considerando aspectos de precisión y novedad en la calidad de la recomendación.

1.4. Contribuciones

El aporte investigativo del presente proyecto se centra en la propuesta de un sistema de recomendaciones para entornos de publicidad ubicua, específicamente en escenarios de digital signage, que expande el espacio *Usuario x Item* tradicional a un espacio *Usuario x Item x Contexto*, incorporando información de confianza entre usuarios a partir de su círculo social cercano, la cual es inferida desde una red social de uso masivo como Facebook. Esto permitirá mejorar la calidad de las recomendaciones a nivel grupal e individual teniendo en cuenta aspectos de precisión y novedad. Igualmente, la incorporación de un *modelo de cooperación Smart TV – Smartphone* para apoyar el despliegue de las recomendaciones, busca enriquecer el enfoque tradicional de public display haciéndolo más interactivo a través de una aproximación multi-pantalla. A través de este esquema, se permite la visualización de recomendaciones grupales en el televisor, al tiempo que se usa la pantalla de los teléfonos para interactuar con ellas o incluso, para habilitar la recepción de recomendaciones personalizadas más acordes al perfil individual del usuario. De otro lado, este

1.4. Contribuciones

esquema favorece igualmente el modelo de persuasión, dado que las recomendaciones grupales que se observan en el televisor pueden resultar novedosas para cada usuario del grupo con respecto a la información que se entregar de acuerdo a sus perfiles individuales, una contribución significativa en entornos de digital signage [19].

Por otro lado, la incorporación de este tipo de modelo, acerca esquemas publicitarios novedosos a los pequeños y medianos comerciantes, redefiniendo incluso, el concepto de publicidad como tradicionalmente se conoce. De acuerdo a la definición de Kotler y Keller presentada al principio de este capítulo, la forma remunerada para la promoción de bienes y servicios, se produce porque generalmente los auspiciantes no son los dueños de los canales publicitarios (canales de televisión, periódicos o páginas Web) y en medios masivos como la televisión, los costos suelen ser muy elevados. Bajo la aproximación propuesta, un modelo de publicidad apoyado en un esquema de cooperación Smart TV - Smartphone puede ser más asequible para el pequeño comerciante, reduciendo incluso los costos al brindarle la posibilidad de ser el dueño del canal publicitario.

A continuación, se resumen de manera general los principales aportes de la presente tesis doctoral:

- *Algoritmo de inferencia de confianza a partir de la información disponible en la red social Facebook:* el algoritmo desarrollado calcula un score de confianza para cada uno de los amigos de un usuario objetivo de acuerdo a la información de sus interacciones en la red social Facebook. Específicamente, se usaron cuatro variables durante el proceso de inferencia (mensajes en el inbox, comentarios, posts en el muro y tags), partiendo de la experiencia de investigaciones previas y validaciones realizadas a través de pruebas de *ground truth*.
- *Algoritmo de filtrado colaborativo basado en confianza:* se modifica un algoritmo de filtrado colaborativo clásico para incluir el componente de confianza que se obtiene a través del procedimiento al que se hizo referencia en el aporte anterior. Específicamente, se diseña una ecuación que pondera la contribución de los componentes de similitud (el cual se calcula a través de un coeficiente de correlación de Pearson, Spearman o equivalente) y confianza, lo cual facilita el ajuste del comportamiento del sistema de recomendaciones en la práctica de acuerdo al balance de precisión y novedad esperado.
- *Esquema de cooperación Smart TV - Smartphone como soporte de un sistema de recomendaciones:* el middleware desarrollado habilita una comunicación transparente entre dispositivos Smart TV y Smartphones con fines no sólo interactivos sino a nivel de despliegue multi-pantalla, lo cual constituye la esencia de un esquema en el cual los dispositivos cooperan para ofrecer contenidos complementarios en cada una de las pantallas. Conceptualmente, la idea de soportar un sistema de recomendaciones a través de un esquema de cooperación de este tipo constituye una novedad importante

con respecto a investigaciones previas que han concentrado sus esfuerzos en la mejora de los algoritmos de recomendación per se, obviando los beneficios que se pueden obtener a través de una mejor estrategia de despliegue en cuanto a precisión y novedad. Aunque se tuvo la oportunidad de diseñar un piloto interesante para escenarios de digital signage, las características del middleware lo hacen fácilmente adaptable a otros dominios.

- *Método de referencia para evaluar un sistema de recomendaciones desde una perspectiva precisión/novedad para entornos de publicidad ubicua:* a partir del framework presentado por [20], se define una métrica para cuantificar de forma simple la novedad en las recomendaciones teniendo en cuenta aspectos relacionados con el ranking (posición en la lista) y la relevancia de las sugerencias para los usuarios. Esto permite comparar y ajustar el balance entre la precisión y la novedad del sistema de recomendaciones, teniendo en cuenta las características del esquema multi-pantalla sobre el cual se encuentra soportado, una característica deseable en el dominio de la publicidad ubicua.

1.5. Publicaciones

Como resultado del proceso de desarrollo de la presente tesis doctoral, se publicaron los siguientes papers en revistas y eventos especializados:

- Francisco Martinez-Pabon, Juan Camilo Ospina-Quintero, Gustavo Ramirez-Gonzalez, and Mario Munoz-Organero, "Recommending Ads from Trustworthy Relationships in pervasive environments" *Mobile Information Systems*, vol. 2016, Article ID 8593173, 2016. *Categoría Colciencias: A2. JCR indexed, Impact Factor: 0.949. (Anexo 1).*
- Francisco Martinez-Pabon, Jaime Caicedo-Guerrero, Jhon Jairo Ibarra-Samboni, Gustavo Ramirez-Gonzalez, and Davinia Hernández-Leo, "Smart TV - Smartphone Multiscreen Interactive Middleware for Public Displays" *The Scientific World Journal*, vol. 2015, Article ID 534949, 2015. *Categoría Colciencias: A1. JCR indexed (Listed 2013), Impact Factor: 1.219. (Anexo 2).*
- Francisco Martinez-Pabon, Juan Camilo Ospina-Quintero, Gustavo Ramirez-Gonzalez, "Recommender System supported on a Smart TV - Smartphone cooperation framework for pervasive advertisement environments" presented at CITA 2015, VII Congreso Iberoamericano de Telemática, Simposio Doctoral. Popayán (Colombia), 10 - 12 Junio 2015. *Categoría Colciencias: N/A (Anexo 3).*
- Kalpani Manathunga, Davinia Hernandez-Leo, Jaime Caicedo-Guerrero, Jhon Jairo Ibarra-Samboni, Francisco Martinez-Pabon, and G. Ramirez-Gonzalez, "Collaborative Learning Orchestration Using Smart Displays and Personal Devices" in *Design for Teaching and Learning in a Networked World*, G. Conole, T. Klobucar, C. Rensing, J. Konert, and È. Lavoué, Eds. Springer International Publishing, pp. 596–600, LNCS Volume 9307, 2015. *Categoría Colciencias: A2 (Anexo 4).*

1.6. Estructura del documento

- Francisco Martinez-Pabon, Jaime Caicedo-Guerrero, Jhon Jairo Ibarra-Samboni, Gustavo Ramirez-Gonzalez, Mario Munoz-Organero and Angela Chantre-Astaiza, "Smart TV - Smartphone Cooperation Model on Digital Signage Environments: An Implementation Approach" presented at the IARIA Mobility 2014, The Fourth International Conference on Mobile Services, Resources, and Users. París (Francia), 20 - 24 Julio 2014. *Categoría Colciencias: N/A (Anexo 5)*.
- Francisco Martinez-Pabon, Juan Camilo Ospina-Quintero, Victor Garzon-Marin, Angela Chantre-Astaiza, Mario Munoz-Organero and Gustavo Ramirez-Gonzalez, "Enriching Public displays Ads recommendations using an individual - group cooperation model" presented at the ACM Pervasive Displays 2014, The Third International Symposium on Pervasive Displays. Copenhage (Dinamarca), 3 - 4 Junio 2014. *Categoría Colciencias: N/A (Anexo 6)*.
- Francisco Martinez-Pabon, Victor Garzon-Marin, Juan Camilo Ospina-Quintero, Jhon Jairo Ibarra-Samboni, Jaime Caicedo-Guerrero, Angela Chantre-Astaiza, and Gustavo Ramirez-Gonzalez, "Sistema de recomendaciones para entornos de Digital Signage soportado en un esquema de cooperación Smart TV-Smartphone" Revista Ingenierías Universidad de Medellín, vol. 24, no. 13, pp. 181-196, 2014. *Categoría Colciencias: A2 (Anexo 7)*.
- Francisco Martinez-Pabon, Gustavo Ramirez-Gonzalez and Angela Chantre-Astaiza, "Modelo conceptual para el despliegue de publicidad ubicua soportado en un esquema de cooperación Smart TV - Smartphone" Revista Ciencia e Ingeniería Neogranadina, vol. 24, no. 1, pp. 116-142, 2014. *Categoría Colciencias: B (Anexo 8)*.

1.6. Estructura del documento

A continuación se describe brevemente el contenido de cada uno de los capítulos subsiguientes que componen el presente documento:

- *Capítulo 2*: realiza un análisis de los trabajos relacionados más importantes para el contexto de la presente investigación, identificando las brechas de conocimiento que finalmente demarcaron el foco de trabajo de la tesis doctoral.
- *Capítulo 3*: describe los aspectos fundamentales del esquema de cooperación Smart TV - Smartphone que se ha construido para soportar la entrega de recomendaciones en un entorno de publicidad ubicua.
- *Capítulo 4*: describe los aspectos más relevantes relacionados con la construcción del sistema de recomendaciones, el cual utiliza un filtrado colaborativo que incorpora información de confianza que se infiere de la red social de los usuarios, más específicamente de la red social Facebook.
- *Capítulo 5*: describe el conjunto de pruebas que se realizaron para evaluar diferentes aspectos del sistema de recomendaciones para entornos de publicidad ubicua

basado en un esquema de cooperación Smart TV - Smartphone. En términos generales, el entorno de pruebas se desarrolla alrededor de un piloto en el dominio de Digital Signage que permite hacer una evaluación de manera integral tanto a nivel del sistema de recomendaciones (teniendo en cuenta aspectos de precisión/novedad) como a nivel del middleware Smart TV - Smartphone que soporta el modelo de cooperación construido.

- *Capítulo 6:* se plantean las conclusiones más relevantes de la tesis doctoral y se describen algunos trabajos futuros que pueden emerger a partir de la presente investigación.

Capítulo 2

Estado del arte

Este capítulo realiza un análisis de los trabajos relacionados más importantes para el contexto de la presente investigación, identificando las brechas de conocimiento que finalmente demarcaron el foco de trabajo de la tesis doctoral. En primera instancia, se describirá la metodología de revisión utilizada en la construcción del estado del arte y posteriormente se realizará un análisis de trabajos previos más relevantes en tres categorías específicas: sistemas de recomendaciones para entornos de publicidad ubicua, sistemas de recomendaciones basados en contexto y sistemas de recomendaciones para grupos y estrategias de despliegue.

2.1. Metodología de revisión

La revisión del estado del conocimiento para la presente tesis doctoral, se abordó a través de una perspectiva de vigilancia tecnológica, la cual se define como “la búsqueda, detección, análisis y comunicación de informaciones orientadas a la toma de decisiones sobre amenazas y oportunidades externas en el ámbito de la ciencia y tecnología” [21]. En términos generales, se abordaron cuatro fases para la construcción del estado del arte (Figura 2.1):

- **Planeación:** identifica las necesidades de información y el enfoque de la vigilancia tecnológica sobre el tema de interés. Durante esta fase, fue definido el objetivo de la vigilancia, se identificaron las fuentes de información más relevantes y las palabras clave que orientaron el proceso de búsqueda de información. En la tabla 2.1, se presenta un resumen al respecto. Haciendo referencia a las palabras clave, inicialmente se realizó una búsqueda preliminar utilizando un conjunto de cinco palabras clave: Ubiquitous advertising, Pervasive Advertising, Contextual Advertising, Pervasive Computing, Ubiquitous Computing y Smart TV. A partir de un estudio preliminar de los abstracts de los papers arrojados por la búsqueda, fue posible determinar que algunas palabras clave arrojaban resultados irrelevantes para el contexto de investigación. A partir de este primer filtro, se tomó la decisión de enfocar el análisis en los resultados de las búsquedas realizadas a partir de las palabras clave señaladas en la tabla 2.1.

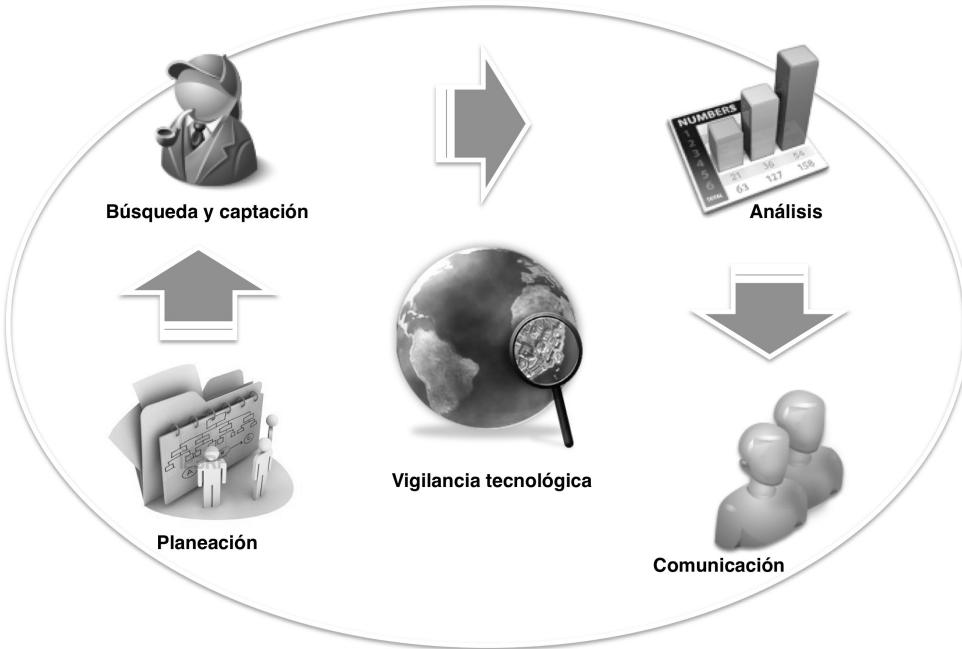


Figura 2.1: Fases vigilancia tecnológica. Fuente Propia.

Objeto general del estudio	Construir una visión general del estado actual del conocimiento en el área de la publicidad ubicua
Objeto específico del estudio	Identificar los focos de investigación más relevantes Identificar los autores más relevantes Identificar las revistas y eventos más destacados en la temática
Identificación de fuentes de información	Google Scholar ACM Digital Library IEEE Xplore Digital Library Science Direct
Palabras clave	Pervasive advertising, ubiquitous advertising, contextual advertising

Tabla 2.1: Planeación de la vigilancia tecnológica

2.1. Metodología de revisión

- **Búsqueda y captación:** durante esta fase se realiza el proceso de búsqueda usando las fuentes de información identificadas, de acuerdo a los objetivos planteados en la fase anterior. El principal resultado de esta fase, es la construcción de un corpus compuesto por los papers más relevantes sobre la temática del proyecto, que constituyen el insumo básico para el análisis que se realizará en la siguiente fase. En total se identificaron más de 200 papers.
- **Análisis:** en esta fase se realiza un análisis exhaustivo de la información del corpus construido en la fase anterior, de acuerdo a los objetivos planteados para el esquema de vigilancia tecnológica. Para este propósito, se tuvo el soporte de dos paquetes software: Matheo Analyzer y Publish or Perish. Matheo analyzer, es un software de apoyo a la toma de decisiones que permite crear un cuadro de mando con mapas de información, síntesis e indicadores a partir de grandes conjuntos de información [22]. Por otro lado, Publish or Perish, es un software libre que permite conocer el impacto de las publicaciones a través de la información que se obtiene de Google Scholar [23]. A manera de demostración sobre algunos resultados descriptivos, la figura 2.2 resume autores relevantes identificados, la figura 2.3 muestra algunos de los artículos más citados y finalmente la figura 2.4 condensa algunas conferencias de interés.

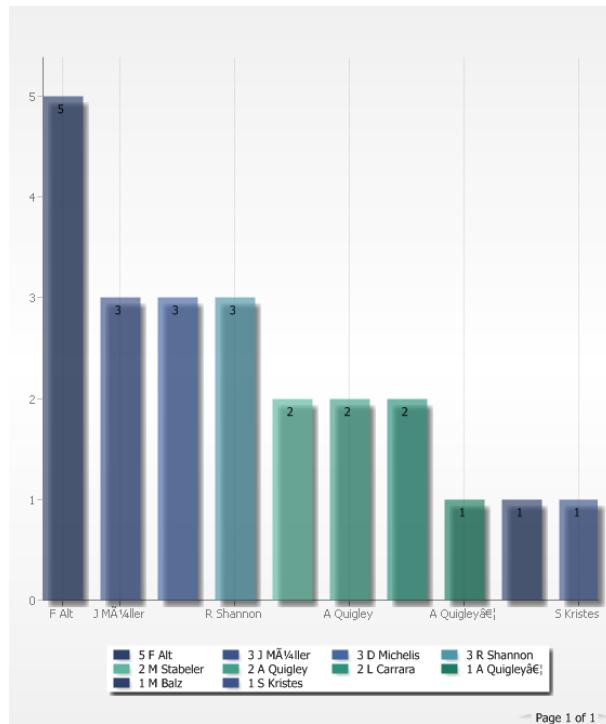


Figura 2.2: Autores más relevantes. Fuente Matheo Analyzer.

- **Comunicación:** el objetivo de esta fase, es presentar los resultados obtenidos durante el proceso de análisis realizado en la vigilancia tecnológica, los cuales fueron socializados en el seminario de investigación realizado al interior del Doctorado y que además

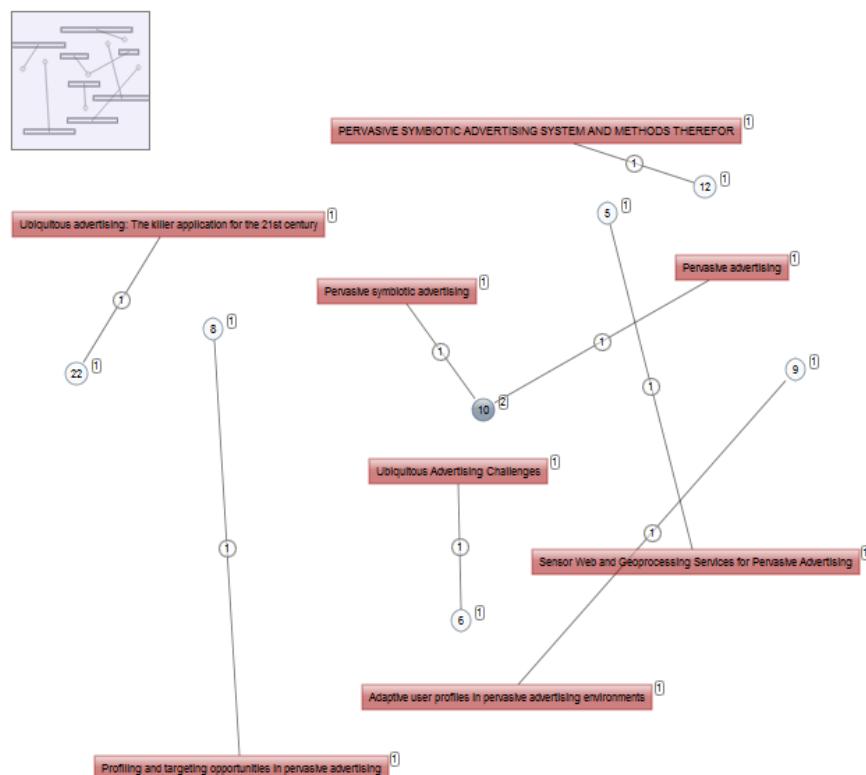


Figura 2.3: Papers más citados. Fuente Mattheo Analyzer.

2.1. Metodología de revisión

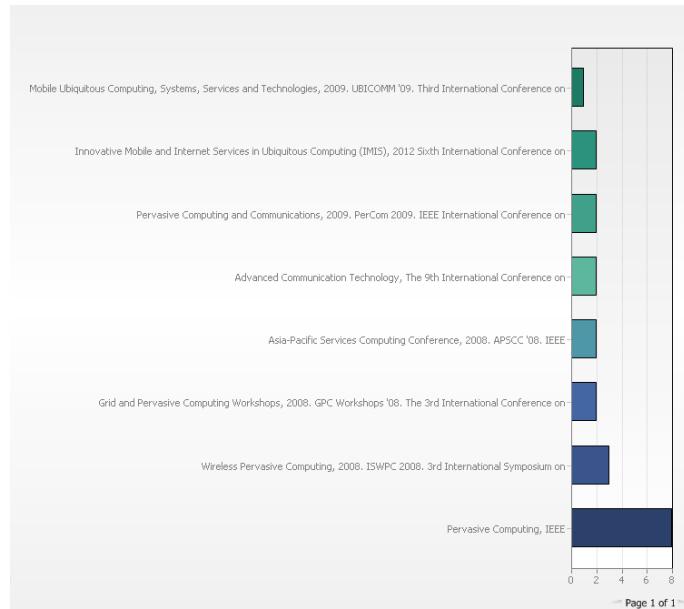


Figura 2.4: Revistas y conferencias más relevantes. Fuente Matheo Analyzer.

fueron condensados en el artículo *Modelo conceptual para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone*.

De manera general, los resultados del proceso de vigilancia tecnológica se pueden resumir en los siguientes puntos: *i)* aunque la publicidad ubicua es un área de investigación que se ha venido cultivando desde hace varios años, el contexto de investigación planteado, que además considera un entorno de cooperación Smart TV - Smartphone, ha sido poco explorado; como soporte a esta evidencia, la mayoría de trabajos relacionados han sido publicados en eventos, más que en revistas especializadas; *ii)* un análisis más profundo de las publicaciones más relevantes, demuestra que existe un énfasis importante en el área de digital signage y el uso de Smartphones con fines de publicidad ubicua, pero no se considera un contexto propiamente dirigido a la incorporación del modelo de Smart TV; *iii)* adicionalmente, es posible inferir la importancia de los sistemas de recomendaciones en la búsqueda de entornos personalizados, pero su aplicación en entornos de publicidad ubicua, especialmente en escenarios de digital signage, es aún materia de investigación.

En síntesis, como resultado del proceso de vigilancia tecnológica se construyó un modelo conceptual compuesto por los tópicos más relevantes de investigación en la temática (figura 2.5). A partir de las conclusiones generadas, se realizó la elección del foco de trabajo de la presente tesis doctoral el cual estuvo dirigido al mejoramiento de los algoritmos de recomendación involucrando información de contexto, pero soportado en un mejor esquema de despliegue para los anuncios publicitarios a través de un esquema Smart TV - Smartphone bajo las hipótesis descritas en el capítulo anterior.

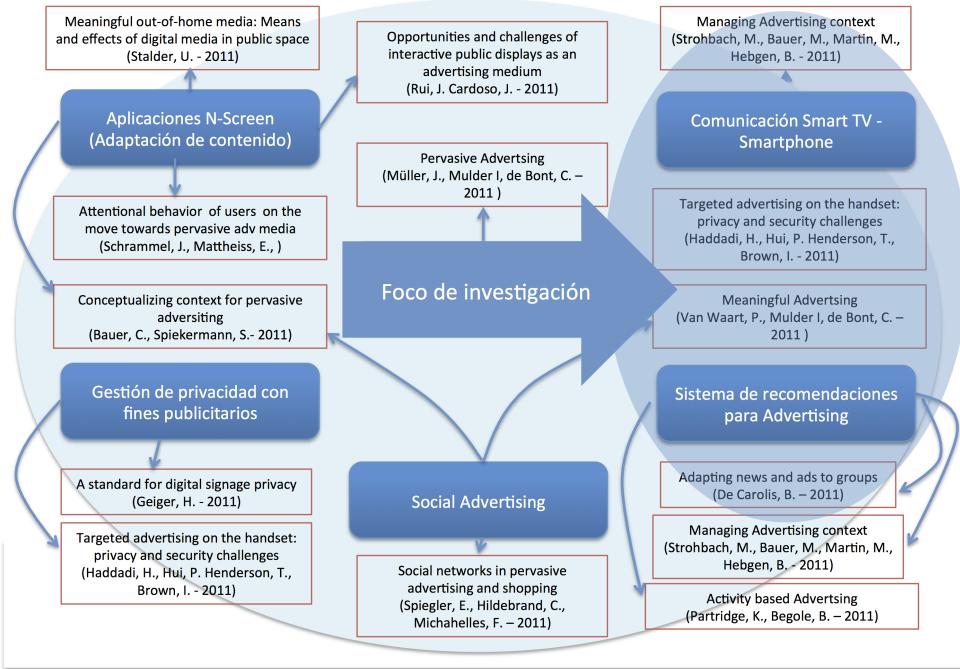


Figura 2.5: Estado actual del conocimiento. Fuente Propia.

De acuerdo al contexto del trabajo de investigación y al foco seleccionado, los trabajos relacionados se han agrupado en tres categorías para facilitar su presentación: sistemas de recomendaciones para entornos de publicidad ubicua, sistemas de recomendaciones basados en contexto y sistemas de recomendaciones para grupos y estrategias de despliegue.

2.2. Sistemas de recomendaciones para entornos de publicidad ubicua

Los sistemas de recomendaciones (SR) basan su funcionamiento en las teorías de minería de datos (data mining) y aprendizaje automático (machine learning) y han sido estudiados desde hace más de dos décadas [24]. Al respecto, algunos trabajos condensan los conceptos, algoritmos y técnicas más relevantes de este campo: [25], [26] realizan un compendio interesante sobre la evolución de las investigaciones relacionadas con sistemas de recomendaciones en un contexto general; igualmente, algunas plataformas como Mahout de Apache [27] o Lenskit [28] han surgido como soporte en la construcción de SR tanto en el contexto comercial como académico. Por otro lado, varios trabajos han abordado los problemas comunes a los sistemas de recomendaciones tradicionales desde diferentes perspectivas: los sistemas basados en contenido y filtrado colaborativo, sufren la existencia del problema del usuario o ítem nuevo (cold start) cuando no se tiene la cantidad de ratings suficientes para realizar la recomendación; al respecto, [29], [30] proponen algunas técnicas que pueden ser complementadas con la utilización de filtros basados en comunidad, según

2.2. Sistemas de recomendaciones para entornos de publicidad ubicua

lo sugieren las investigaciones de Golbeck [31] y Massa [32]. Otros problemas, relacionados con la dispersión de los datos (pocos ratings para gran parte de los ítems disponibles), han sido abordados en [33–36]; por otro lado, la combinación de los diferentes tipos de filtrado para robustecer las capacidades del SR, conocido como filtrado híbrido, han sido ampliamente estudiados a través del empleo de diferentes técnicas [37–42]. No obstante, aunque el aporte conceptual es importante para el marco de cualquier trabajo relacionado con SR, el dominio de aplicación es un aspecto fundamental y ninguna de estas investigaciones se ubica específicamente en el campo de la publicidad ubicua. Al respecto, [43] señala que “el desarrollador de un sistema de recomendaciones para un dominio de aplicación específico, debería entender los requerimientos particulares del dominio, sus desafíos y limitaciones de aplicación”; de esta afirmación, se deduce que aunque los sistemas de recomendaciones comparten un núcleo común, el dominio de aplicación fija importantes pilares a la investigación que se pretenda realizar.

En este sentido, algunas investigaciones han empezado a recorrer el camino para caracterizar el dominio de la publicidad ubicua como insumo básico de cualquier trabajo de investigación en esta área. [4], [18] ofrecen una conceptualización interesante sobre la publicidad ubicua, sus principales características, retos y oportunidades; asimismo, se realiza una descripción de las tecnologías clave en la implementación de modelos de este tipo. Al respecto, [44], [45] plantean un marco de referencia relacionado con dicha implementación, pero principalmente orientado a teléfonos móviles y usuarios individuales, sin hacer énfasis en sistemas de recomendaciones. Por su parte, [46] analiza algunos aspectos relacionados con el desarrollo de sistemas de recomendaciones en diferentes dominios y específicamente [15] realiza un estudio preliminar sobre la implementación de SR en entornos publicitarios a través de una aproximación colaborativa con un énfasis especial en la adquisición de información y preferencias de usuario, incluyendo información contextual relacionada con la localización, actividad en curso y hora del día. Sin embargo, aunque se plantea una aproximación para representar la información del usuario, la adquisición de las preferencias se realiza de forma explícita y no se profundiza en el esquema de generación de las recomendaciones como tal.

Con respecto a este último punto, es importante tener en cuenta que los sistemas de recomendaciones, especialmente aquellos que usan filtrados colaborativos, generalmente son procesos estocásticos que son aproximaciones heurísticas de procesos humanos [47]. Por consiguiente, la experimentación y las métricas de evaluación que se aplican a los algoritmos son elementos clave para determinar su rendimiento en muchos aspectos; [48], [49] presentan una descripción detallada de las métricas frecuentemente usadas, incluyendo además un marco metodológico para su aplicación. En este contexto, frecuentemente la precisión de los algoritmos al momento de generar las recomendaciones es una preocupación constante, pero en entornos de publicidad ubicua lograr una alta precisión podría traducirse en recomendar ítems que son suficientemente conocidos por los usuarios [50]. Por esta razón, la novedad en las recomendaciones es un aspecto deseable en este tipo de entornos y constituye un insumo importante para lo que se conoce como tecnología de persuasión,

una característica deseable en entornos publicitarios; en este sentido, una manera palpable de lograr su implementación es mejorando el grado de novedad en las recomendaciones, ofreciendo alternativas que pueden llegar a ser interesantes para los usuarios. Aunque su enfoque no es precisamente en el dominio de la publicidad ubicua, algunos trabajos han abordado el tema: [50] propone nuevas direcciones centradas en el usuario para evaluar los RS, entre las cuales se encuentra el grado de novedad; [51] analiza el rol de la cobertura y la novedad como indicadores de la calidad de la recomendación y presenta algunos métodos para medirlo e interpretar los resultados; por su parte, [52] propone un algoritmo para generar recomendaciones novedosas, tomando como insumo el tiempo de búsqueda que cada usuario invertiría para encontrar un ítem novedoso sin la presencia del SR, partiendo de la hipótesis que el grado de sorpresa es proporcional al tiempo de búsqueda estimado; otra estrategia propuesta por [53] enriquece un algoritmo de recomendación basado en grafos con un conocimiento de sustento que permite encontrar correlaciones ocultas entre los ítems para proporcionar sugerencias no obvias y por ende más novedosas. No obstante, el trabajo realizado por [20] presenta un framework formal para la definición de métricas de novedad y diversidad que unifica diferentes aproximaciones que se encuentran en la literatura; específicamente, el ranking (posición en la lista) y la relevancia del ítem son incluidos a través de un modelo de navegación probabilístico sobre las recomendaciones. Esta aproximación constituye un punto de partida importante para los propósitos de la presente tesis doctoral, teniendo en cuenta la posibilidad de adaptarlo a los requerimientos específicos del dominio de la publicidad ubicua como se verá en la sección 4.4 del capítulo 4.

2.3. Sistemas de recomendaciones basados en contexto

La construcción de SR para entornos de publicidad ubicua agrega nuevos retos a los focos de investigación que tradicionalmente se han abordado como fue descrito en la sección anterior. En primer lugar, los SR convencionales operan en un espacio bidimensional *Usuario x Item*. Sin embargo, la publicidad ubicua requiere la incorporación de información del contexto que debe ser tenida en cuenta al momento de formular la recomendación, lo cual sugiere la ampliación del espacio tradicional *Usuario x Item* a un espacio *Usuario x Item x Contexto*. Al respecto, [54] y [55] realizan algunos aportes para el modelamiento del contexto del usuario en entornos más generales, mientras que [56] va un paso más allá y define una metodología para la caracterización del contexto en entornos de publicidad ubicua; en el mismo sentido, [57] y [58] examinan algunas técnicas para la incorporación de información contextual en los SR y [15] plantea la incorporación de algunos datos relacionados con el contexto de localización en un entorno de publicidad. No obstante, el enriquecimiento de los perfiles es clave para propósitos de publicidad, más allá de la disponibilidad de ratings [59].

En este sentido, [11] plantea una conceptualización más profunda sobre el contexto en entornos de publicidad ubicua que incluye una taxonomía que parte del modelo de Schmidt [60], en donde se incluye el ambiente social como parte del contexto del usuario. Desde el

2.3. Sistemas de recomendaciones basados en contexto

punto de vista de los SR para entornos de publicidad ubicua, esta conclusión resulta interesante si se tiene en cuenta que los SR colaborativos tradicionales basan sus modelos de predicción en las opiniones de usuarios anónimos; la inclusión de redes basadas en confianza derivadas del entorno social del usuario podría mejorar el impacto de las recomendaciones para el usuario objetivo, si se tiene en cuenta que un reporte de McKinsey/Thompson se establece que el 67 % de las decisiones de compra están influenciadas por personas cercanas [61]. Este es un foco de especial interés para la presente propuesta de investigación.

Al respecto, dada la naciente exploración que se tiene en este campo, los resultados de las investigaciones son aún diversos. [31], [32] reportan que las recomendaciones basadas en redes sociales no son más precisas que las derivadas a partir de los filtros colaborativos clásicos, excepto en casos especiales donde los ratings de los usuarios para un ítem específico son altamente controversiales, o cuando se usan como alternativa para solucionar los inconvenientes asociados a los “usuarios” o “items” nuevos (cold start). Otros trabajos han demostrado que en algunos casos, la adición de datos sociales a los sistemas tradicionales mejora los resultados de las recomendaciones con respecto a los datos de similitud de perfiles [62], [63]. Recientemente, un ingrediente adicional se ha sumado a las investigaciones en este escenario: la confianza entre usuarios; en términos simples, una red de confianza se refiere a una red social que expresa qué tanto confían los miembros de una comunidad entre sí [31]. Un ejemplo de esta aproximación puede evidenciarse en la red social Epinions.com [64], la cual mantiene una red de confianza al indagar en los usuarios acerca de las personas en las cuales confían. Los sistemas de recomendaciones basados en esta técnica, usan el conocimiento que se origina a partir de las relaciones de confianza para brindar recomendaciones más personalizadas a través de operadores de propagación y agregación, lo cual permite a los usuarios recibir recomendaciones de ítems que han logrado una alta calificación por parte de los usuarios en su red o aún por las personas que hacen parte de las redes de confianza de estos individuos.

En general, la inclusión de confianza en los sistemas de recomendaciones puede ser estudiada desde dos aproximaciones: cuando la información de confianza se captura de forma explícita desde los usuarios o cuando la información se infiere a partir de la información de los usuarios. Con respecto a la primera aproximación [32] extendió un algoritmo de recomendación clásico al incluir una matriz de confianza que complementa la matriz de ratings, para reemplazar el mecanismo de predicción tradicional por un algoritmo que calcula la propagación de confianza en la red y la reemplaza por la similitud. [31] desarrolló Film Trust, un sitio Web que usa la confianza inferida desde una red social propietaria para ofrecer recomendaciones de películas; el trabajo se enfoca en determinar como crear interfaces para representar las conexiones entre usuarios basado en la información que ellos mismos han proporcionado, usando un algoritmo denominado Tidal Trust. Otras aproximaciones similares pueden ser consultadas en [65], [66].

Con respecto a la inferencia de confianza, algunos trabajos toman como base la matriz de ratings. Por ejemplo, [67] propone una variante del algoritmo kNN (k-nearest neighbour) el

cual es ampliamente utilizado en las técnicas de filtrado colaborativo, que pretende determinar el grado de confianza entre usuarios al evaluar la utilidad de la información de los ratings que éstos reciben; [32] propone una aproximación similar que busca que el algoritmo se propague por la red y calcule un peso de confianza que pueda sustituir al peso de similitud que usualmente se emplea en los filtros colaborativos clásicos; en el mismo sentido [68] extiende el espacio Usuario x Item a un espacio Usuario x Item x Contexto al generar una matriz de confianza inferida a partir de los ratings de los usuarios, mientras que [69] propone la implementación de dos matrices de factorización basadas en confianza-contexto que considera el modelo de la red de confianza implícito basado en usuario y basado en ítem para capturar la influencia del contexto y la información de confianza en el rating. En el mismo sentido, la propuesta de [70] define un método basado en lógica difusa para considerar los ratings de amigos que se encuentran bajo un cierto umbral de confianza.

De otro lado, algunas propuestas van más allá y tratan de inferir confianza a partir de la información disponible en la red social del usuario. [71] propone un framework de recomendación para redes sociales basado en filtrado colaborativo y confianza usando dos métodos para el cálculo de la similitud entre usuarios: uno basado en la información de sus perfiles y otro basado en las interacciones de las personas, con lo cual un valor único se integra al algoritmo de recomendación. Por otro lado, [72] demostró que las interacciones entre los individuos en una red social son el componente más fuerte al momento de inferir confianza, argumento que ha sido respaldado por otras investigaciones. Por ejemplo, [73] define un modelo predictivo que mapea datos de medios sociales a valores de fortaleza de vínculos entre individuos sobre un dataset con cerca de 2000 enlaces; como resultado, se definieron 15 variables top para la inferencia de confianza. Otras propuestas han usado aproximaciones similares basadas en la información de interacción, encontrando varios acuerdos con el set de variables definido por el trabajo anterior al momento de realizar la inferencia de confianza [74–76]. Estos trabajos fijaron un punto de partida importante para los propósitos de la presente tesis doctoral.

Aunque los trabajos previos demuestran avances importantes en la inferencia de confianza con propósitos de recomendación, se pueden destacar algunas brechas con respecto al contexto de la presente investigación: los ambientes ubicuos exigen la captura de tanta información como sea posible en una forma implícita; en este sentido, los mecanismos que infieren confianza a partir de información proporcionada directamente por los usuarios no lucen atractivos en entornos de publicidad ubicua. Por otro lado, aunque la inferencia de confianza a partir de la propia matriz de ratings o de una versión extendida *Usuario x Item x Contexto* es interesante, esta aproximación aún infiere información a partir de usuarios anónimos lo cual no garantiza que éstos se encuentren en el círculo social más cercano del usuario; de acuerdo a la caracterización realizada para el dominio de la publicidad ubicua, se requiere una inferencia de datos a partir de amigos del usuario objetivo, lo cual es una desventaja de estas técnicas y del propio filtrado colaborativo clásico. Por consiguiente, la inferencia de confianza a partir de la información disponible en redes sociales parece ser una alternativa más adecuada para los propósitos del dominio de investigación, pero el uso

2.4. Sistemas de recomendaciones para grupos y estrategias de despliegue

de redes propietarias restringe la escalabilidad del sistema con propósitos de recomendación. Finalmente, no existe un consenso sobre el mejor conjunto de variables para inferir confianza a partir de la información disponible en redes públicas como Facebook ni tampoco existe una estrategia clara para incluir dicha información en el algoritmo de recomendación, lo cual demanda un estudio más profundo al respecto.

2.4. Sistemas de recomendaciones para grupos y estrategias de despliegue

Tradicionalmente los SR dirigen sus recomendaciones a individuos; no obstante, en el contexto del presente trabajo, dirigido específicamente a digital signage, se requiere que las recomendaciones estén dirigidas a un grupo de personas que se encuentran observando una pantalla de avisos publicitarios en un momento determinado; el impacto en este tipo de escenarios desde el punto de vista publicitario es alto si se tiene en cuenta que el 75 % de las decisiones de compra se toma en los puntos de venta, o cerca de ellos [11], donde usualmente se pueden localizar este tipo de pantallas. Al respecto, dos factores merecen ser analizados: en primer lugar, las técnicas que permiten al SR analizar perfiles grupales para generar las recomendaciones y en segundo lugar, las alternativas para su correcto despliegue en un esquema más interactivo.

Con respecto al primer factor, [77] realiza un análisis interesante sobre los retos que supone la generación de recomendaciones grupales y [78] discute diferentes estrategias para combinar preferencias de usuarios y adaptarlas a grupos con fines de recomendación, específicamente para ítems televisivos; igualmente, [79] analiza no sólo la generación de recomendaciones grupales a partir de técnicas como las presentadas en el trabajo anterior, sino que también estudia la conformación más óptima de grupos a partir del conjunto de sugerencias. En el mismo sentido, algunos sistemas han sido diseñados en diferentes dominios con fines de recomendación grupal: Polylens [80], un componente del sistema MovieLens orientado a ofrecer recomendaciones sobre películas, el cual utiliza un algoritmo que combina listas de recomendaciones para usuarios individuales y las organiza en orden decreciente de preferencia; MusicFx [81], un sistema diseñado para seleccionar canciones de acuerdo a las preferencias de grupos de usuarios, basado en una suma de scores normalizados de todos los ítems en la lista de preferencias; Intrigue [82], [83] es un sistema turístico que apoya en el diseño de tours para grupos de usuarios heterogéneos a partir de un modelo de preferencias de subgrupos homogéneos de usuarios. WheretoGo [84] es un sistema de recomendación para viajes que unifica en un solo framework las relaciones usuario-localización, usuario-usuario y localización-localización, incluyendo un componente dirigido a grupos, el cual fue validado a través del dataset de Flickr. Otras aproximaciones similares son presentadas en [85-87].

Especificamente en el campo de publicidad, [15] plantea una propuesta para la caracterización y el modelamiento de grupos de usuarios, con el fin de entregar recomendaciones

dirigidas a un conjunto de individuos en un gimnasio. Sin embargo, el esquema utiliza una técnica aditiva simple y no profundiza en la evaluación de otras alternativas. De otro lado, el esquema de interacción tiene un componente fuertemente explícito, algo susceptible de mejorar en entornos publicidad ubicua donde es deseable que la interacción sea mucho más implícita.

Pasando al análisis del segundo factor, el naciente modelo de Smart TV expone un potencial interesante para extender las capacidades de interacción de las pantallas publicitarias convencionales tanto en el campo del digital signage como en el de los avisos publicitarios del televidente clásico, gracias a su capacidad de conexión con Smartphones o tabletas. Plataformas como MOVL [88] (adquirida por Samsung) y Beamly [89] (anteriormente denominada Zeebox) han dado los primeros pasos para facilitar la interacción entre Smartphones y Smart TV; la primera define un modelo de conexión en la nube para este tipo de dispositivos y la segunda, promete revolucionar el contexto de la televisión a través de la interacción con las redes sociales Twitter y Facebook usando clientes móviles, abriendo las puertas hacia un nuevo paradigma conocido como aplicaciones n-screen o multi-pantalla. En términos simples, el paradigma de n-screen busca tomar ventaja de las capacidades de cada pantalla para desplegar el contenido de la mejor manera en cada una de ellas [90], más en un esquema de cooperación (contenido complementario en las pantallas), que en una simple réplica de información. En el contexto de la publicidad ubicua, los beneficios pueden ser claramente perceptibles si se tiene en cuenta escenarios de pantallas públicas en los cuales la información desplegada en el Smart TV está dirigida al contexto grupal, mientras que la pantalla de los Smartphones es usada en un contexto individual.

Al respecto, tradicionalmente varios trabajos de investigación se han enfocado en mecanismos de interacción entre las pantallas y los Smartphones a través de tecnologías de corto alcance como NFC o Bluetooth [91–94], las cuales no consideran una colaboración interactiva real entre los dispositivos y en muchos casos se aplica una replicación de información en las pantallas. No obstante, en el marco de la publicidad ubicua es importante la existencia de un esquema que habilite la cooperación entre el Smart TV y los Smartphones. En primera instancia, los trabajos de [8], [9] realizan una caracterización más profunda de los entornos de digital signage, proporcionan algunas guías de diseño de este tipo de espacios y plantean algunas consideraciones importantes que fijan un punto de partida relevante al momento de definir los requerimientos de lo que podría ser un esquema de este tipo. De manera similar, otros trabajos han explorado la interacción de Smartphones con pantallas en el marco del paradigma de n-screen, los cuales según [95] pueden ser agrupados bajo dos grandes aproximaciones: el primer grupo usa una aplicación particular diseñada para las características específicas del sistema de despliegue en un escenario específico, lo cual no la hace portable para otros dominios; algunas investigaciones de la Universidad de Oulu en Finlandia [96], la Universidad de Lancaster en Inglaterra [97], la Universidad de Stuttgart en Alemania [98] y la Universidad de Ottawa en Canadá [99] son algunos ejemplos que siguen esta aproximación. Por otro lado, el segundo grupo depende de la disponibilidad de varias alternativas de comunicación en los dispositivos móviles como Bluetooth, NFC o

2.4. Sistemas de recomendaciones para grupos y estrategias de despliegue

IVR (Interactive Voice Response), lo cual amplía el abanico de posibilidades para lograr una interacción más universal pero a costa de limitar la personalización y el significado compartido de la interacción, de acuerdo a lo planteado por [95]; algunos trabajos de este tipo pueden ser consultados en [91, 92, 100–103]. En este sentido, es claro que un esquema de cooperación Smart TV - Smartphone puede ser una interesante alternativa de investigación para implementar esquemas de interacción multi-pantalla robustos, que hasta el momento ha sido poco explorada.

Al respecto, han surgido algunas plataformas como el Samsung Convergence Framework [104] o Samsumg Multiscreen SDK [105] las cuales definen esquemas de interacción Smart TV - Smartphone propietarios basados en HTTP long polling o Websockets [106]; otras alternativas incluyen plataformas tipo set top box como Google TV y Apple TV; la primera, provee el soporte del ecosistema Android para el desarrollo de aplicaciones a terceros, mientras que la segunda es complementamente cerrada aún para los desarrolladores. No obstante, un análisis más profundo de estas aproximaciones revela una debilidad común: la mayor parte de la interacción ha sido diseñada pensando en el dispositivo móvil como un dispositivo de entrada y en el Smart TV como un dispositivo de salida, lo cual restringe la operación de un esquema de cooperación multi-pantalla real. Por otro lado, algunos trabajos relacionados con sistemas middleware como MAGIC Broker [107], OSGi Broker [108] o UbiBroker [109] exponen características con diferentes niveles de abstracción para las complejidades de comunicación y los diferentes modos de interacción para pantallas públicas proporcionando soporte para múltiples dispositivos a través de un paradigma Web, pero una implementación real de acuerdo al modelo de Smart TV no es del todo obvia, ya que la implementación de formas atractivas de interacción con pantallas públicas demanda la posibilidad de usar gestos y otras características habilitadas en los sistemas operativos, lo cual sugiere el uso de aplicaciones nativas en ambas plataformas (Smart TV, Smartphone).

Capítulo 3

Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

Este capítulo describe los aspectos fundamentales del esquema de cooperación Smart TV - Smartphone que se ha construido para soportar la entrega de recomendaciones en un entorno de publicidad ubicua. Inicialmente, se realiza un análisis de los aspectos más relevantes del dominio de la publicidad ubicua que dieron origen a las características del esquema de cooperación planteado. Posteriormente, se describe la arquitectura base del esquema de cooperación Smart TV - Smartphone, las características del middleware implementado y el modelo de comunicaciones diseñado para soportar el transporte de información en este tipo de entornos.

3.1. Análisis del dominio de la publicidad ubicua

Hasta el momento se ha realizado un análisis conciso del potencial de la publicidad ubicua como eje de las tareas modernas de marketing para pequeñas y grandes compañías, lo cual constituyó una motivación importante para la realización de la presente investigación. A continuación, se realiza una caracterización del dominio de la publicidad ubicua y más específicamente del Digital Signage, desde el punto de vista de los tres retos principales que afrontan este tipo de entornos y que son la base sobre la cual se sustenta la arquitectura propuesta para el esquema de cooperación Smart TV - Smartphone.

En primer lugar, uno de los grandes retos tiene que ver con la personalización y la adaptación al contexto que deben tener los anuncios publicitarios que se despliegan en las pantallas públicas. Normalmente, este tipo de sistemas entregan recomendaciones de anuncios bajo una filosofía broadcast, es decir el mismo set de items es mostrado indistintamente a todos los transeúntes que pasan por el lugar.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

La personalización y adaptación al contexto, ha sido un problema que frecuentemente se ha abordado desde la perspectiva de los sistemas de recomendaciones, como lo plantea el presente trabajo. No obstante, uno de las complejidades más evidentes tiene que ver con el gran número de variables que pueden influenciar el contexto del usuario; por ejemplo, la temperatura del lugar, la ubicación del usuario, sus preferencias, etc., lo cual dificulta su inclusión en el razonamiento de un sistema de recomendaciones práctico. Sin embargo, en el dominio de la publicidad ubicua, una de estas variables cobra especial relevancia y tiene que ver con el contexto social del usuario. Durante años, la técnica de *word of mouth* o *de boca en boca* en español, ha sido utilizada por los especialistas en marketing para lograr persuasión hacia la adquisición de un bien o servicio gracias a las referencias de amigos o conocidos. De acuerdo a lo anterior, la incorporación de esta técnica a través de la inferencia de información que se pueda hacer a partir del contexto social del usuario en el sistema de recomendaciones redundará en interesantes beneficios tanto para los promotores de las campañas publicitarias como para los propios usuarios.

La reflexión anterior sugiere un esquema colaborativo en el sistema recomendaciones. Durante años, el algoritmo de filtrado colaborativo ha sido uno de los más utilizados en la industria y básicamente estima el grado en el cual a un usuario le gusta un ítem en particular con base en el comportamiento de otros usuarios; esto es, encuentra usuarios cuyos ratings son similares a los del usuario objetivo y así genera una predicción. No obstante, la aproximación clásica del algoritmo de filtrado colaborativo confía en los ratings de usuarios que terminan siendo anónimos.[110], [111] demostraron que las personas tienden a confiar más en las recomendaciones de individuos en los que ellos confían que en usuarios anónimos y esa es la base del *word of mouth*. En consecuencia, no sólo la distinción entre amigos y/o conocidos sino el grado de confianza que pueda existir entre ellos, son aspectos clave que deberían tenerse en cuenta en el algoritmo de recomendación. Este tema será abordado con mayor detalle en el siguiente capítulo.

El segundo reto está relacionado con el despliegue de anuncios que puedan ajustarse a las preferencias del grupo de personas que está observando la pantalla pública en un momento determinado. Desde el punto de vista de los sistemas de recomendaciones y como fue contemplado en el estado del arte, las técnicas de agregación han sido propuestas para intentar promediar un conjunto de recomendaciones individuales y constituir un set de recomendaciones que se ajusten al grupo como un todo. Aunque ésta pueda resultar en una aproximación válida en otros contextos, en el dominio del digital signage la aproximación luce incompleta puesto que la satisfacción de los usuarios no estará del todo garantizada, sobre todo a medida que el número de usuarios se incremente. En este sentido, la solución a este desafío, más que en el mejoramiento del algoritmo de recomendación per se, radica en una mejor estrategia de despliegue de las recomendaciones que complementen satisfactoriamente las tareas del sistema de recomendaciones. En este sentido, la propuesta del presente trabajo contempla la definición de un esquema de cooperación entre la pantalla pública (Smart TV) y pantallas personales (Smartphone o Tablet), de tal manera que la primera cumpla funciones de despliegue grupales y la segunda funciones de despliegue

3.2. Arquitectura base esquema de cooperación Smart TV - Smartphone

más personalizadas.

Finalmente, el tercer desafío tiene que ver con la novedad que se introduce en las recomendaciones de los anuncios. Frecuentemente, la precisión ha sido una de las premisas constantes al momento de evaluar un sistema de recomendaciones y aunque no deja de ser relevante en el dominio de la publicidad ubicua, en este caso la novedad de las recomendaciones de anuncios cobra incluso una relevancia superior. La razón, es que una alta precisión de alguna manera vuelve al sistema de recomendaciones predecible y monótono; en el dominio publicitario, frecuentemente los promotores de las campañas buscan la promoción de nuevos productos y servicios, los cuales a la luz de un sistema de recomendaciones tradicional y muy preciso podrían lucir como falsos positivos; luego el balance entre precisión/novedad es una característica deseable en este tipo de dominios. Esta reflexión da lugar a una de las hipótesis más importantes de la presente investigación, la cual plantea que el balance precisión/novedad en entornos de digital signage puede mejorarse igualmente a través de una mejor estrategia de despliegue que complemente la tarea del sistema de recomendaciones. En este orden de ideas, se espera que las recomendaciones grupales generadas por las técnicas de agregación sean menos precisas pero si más novedosas que las recomendaciones recibidas en las pantallas personales, lo cual equilibra la balanza en favor de los usuarios y los advertisers.

3.2. Arquitectura base esquema de cooperación Smart TV - Smartphone

De acuerdo al análisis realizado en la sección anterior, la figura 3.1 muestra la arquitectura base del esquema de cooperación Smart TV - Smartphone definido, el cuál reúne las características necesarias para soportar un sistema de recomendaciones en un entorno de publicidad ubicua, mas específicamente en el dominio del digital signage.

Como se puede observar, el sistema de recomendaciones ha sido diseñado para entregar recomendaciones grupales a través de técnicas de agregación y recomendaciones individuales a través de un algoritmo colaborativo que incorpora inferencia de confianza a partir del círculo social del usuario. La información detallada puede ser consultada en el capítulo 4. No obstante, las tendencias en el estado del arte muestran que la mayoría de las aproximaciones desarrolladas hasta el momento se han enfocado en el mejoramiento o adecuación de los algoritmos de recomendación en sí. Como uno de los grandes aportes del presente trabajo, el esquema de cooperación propuesto agrega un complemento importante a las tareas de recomendación desde el punto de vista de despliegue. Específicamente, el término *cooperación* hace referencia a la naturaleza colaborativa del sistema al momento de entregar las recomendaciones bajo dos aproximaciones diferentes pero complementarias: recomendaciones de anuncios para perfiles grupales en el Smart TV y recomendaciones personalizadas en la pantalla del Smartphone.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

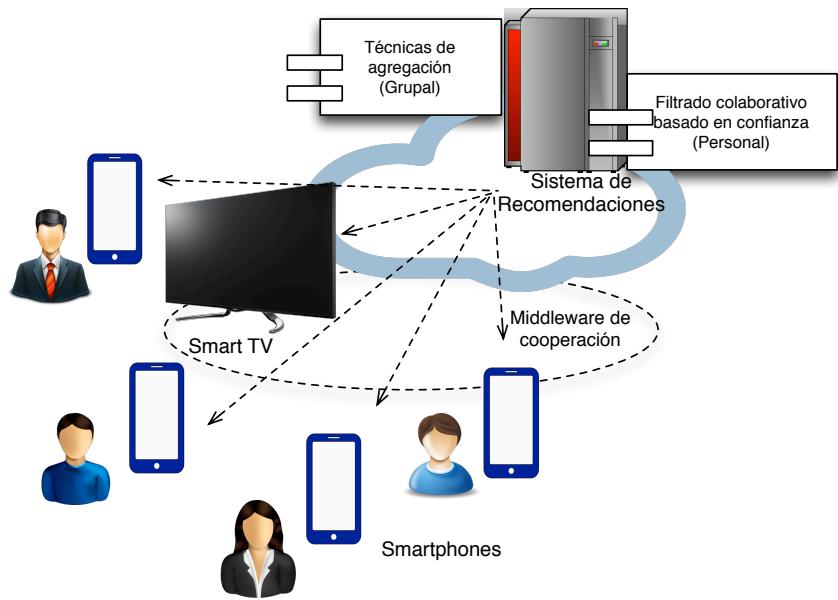


Figura 3.1: Arquitectura base esquema de cooperación Smart TV - Smartphone. Fuente Propia.

Por otro lado, es importante aclarar que la elección de un esquema de cooperación Smart TV - Smartphone para entornos de digital signage tiene una motivación adicional: los entornos publicitarios modernos demandan funciones más interactivas con el objeto de brindar al usuario más que una campaña, una verdadera *experiencia publicitaria*. En un escenario clásico, el usuario observa y asimila o ignora el contenido publicitario; en una aproximación moderna, el usuario interactúa con los anuncios y esa experiencia puede generar una persuasión más efectiva [18]. En este tipo de experiencias, el usuario puede navegar por los anuncios de la pantalla pública y detallar la información de su interés en la pantalla personal por ejemplo. En escenarios más enriquecidos, el usuario podría lanzar un tomate virtual desde su teléfono hacia un anuncio que no es de su agrado o concursar a lanzar la pelota de tennis lo más lejos posible desde su Smartphone hacia la pantalla pública en una campaña que promociona un gran partido de temporada.

Aunque el modelo de Smart TV ofrece capacidades de conexión para dispositivos móviles circundantes, normalmente estas facilidades están pensadas para entornos más domésticos con un número de usuarios limitado. Por ejemplo, el Samsung Convergence Framework ofrece una capacidad de conexión para 4 usuarios. De acuerdo a lo anterior, el presente trabajo propone el desarrollo de un middleware de cooperación Smart TV - Smartphone como implementación de referencia para el modelo propuesto.

A partir de los planteamientos realizados para la caracterización del modelo de cooperación Smart TV - Smartphone, se derivan las dos principales hipótesis que guían la realización del presente trabajo de investigación:

3.3. Middleware de cooperación Smart TV - Smartphone

H1: *la inclusión de esquemas de cooperación multipantalla para la entrega de recomendaciones mejoran el balance precisión/novedad*

H2: *la inclusión de información de confianza en el algoritmo de filtrado colaborativo contribuye positivamente en el mejoramiento del balance precisión/novedad*

3.3. Middleware de cooperación Smart TV - Smartphone

En esta sección se describirá la arquitectura propuesta para el middleware de cooperación Smart TV - Smartphone. En primer lugar se presentarán una serie de requisitos que el middleware debería cumplir de acuerdo a las características de los entornos de digital signage; estos requisitos fueron definidos a partir de las contribuciones de trabajos relacionados previos y la experiencia adquirida durante la construcción de los pilotos. Posteriormente se describirá la arquitectura y el modelo de comunicaciones implementado.

3.3.1. Requerimientos

3.3.1.1. Modelo de comunicación de bajo acoplamiento

En un sistema interactivo que involucra pantallas públicas y dispositivos móviles, los usuarios frecuentemente lanzan acciones a través de comandos desde sus Smartphones que normalmente esperan por una respuesta desde la pantalla principal. Esta característica demanda un ambiente altamente dinámico con soporte para comunicaciones ad-hoc entre los nodos relacionados, evitando interfaces altamente acopladas. De acuerdo a los trabajos de [107],[109],[112],[113] una de las mejores alternativas para la implementación de esta característica, consiste en un modelo de comunicaciones basado en eventos que soporte un esquema de interacción Publisher/Subscriber.

3.3.1.2. Estabilidad

Es deseable que el middleware proporcione una estabilidad razonable con un bajo número de caídas y fallas del sistema con el objeto de garantizar una interacción más fluída. De acuerdo al modelo para el manejo de mensajes expuesto en el punto anterior, gran parte de la responsabilidad para el cumplimiento de este requisito recae sobre el modelo de comunicaciones utilizado. En ese orden de ideas, de acuerdo al trabajo de [109] la estabilidad puede convertirse en un requisito dispendioso cuando el middleware se construye desde cero, puesto que esta característica se estabiliza con el tiempo luego de un proceso de desarrollo continuo y un testeo cuidadoso. En consecuencia, el presente trabajo toma como base soluciones suficientemente testeadas con el fin de adaptarlas a las funcionalidades requeridas en cada uno de los componentes del middleware como se verá más adelante.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

3.3.1.3. Apertura

Una de los requisitos más importantes que se ha considerado durante la construcción del middleware es la capacidad de evolucionar a partir del soporte de estándares y tecnologías abiertas. En este sentido, la evolución puede reflejarse a través de diferentes esquemas: adición de nuevas características, adición de nuevos protocolos, modificación de los existentes o interconexión con otro tipo de sistemas. Este tipo de aproximación favorece igualmente la integración con aplicaciones desarrolladas por terceros.

3.3.1.4. Simplicidad

El middleware debe exponer sus servicios a través de una API pública que pueda ser adoptada fácilmente por terceros que deseen explotar sus capacidades, dada la complejidad que usualmente refleja el modelo de comunicaciones de un middleware de este tipo [114]. En este sentido, es deseable la construcción de una API simple que involucre patrones de diseño y brinde implementaciones de referencia que faciliten el desarrollo de aplicaciones usando las capacidades del middleware.

3.3.1.5. Interacción concurrente

Los ambientes de digital signage demandan un entorno multi-usuario que involucra interacciones directas e indirectas con la pantalla pública [9]. En este sentido, el middleware debe soportar la interacción concurrente de múltiples Smartphones con uno o más Smart TV; el número de usuarios deberá ser lo suficientemente amplio y limitado sólo por el tamaño disponible para el despliegue de información en el Smart TV. De la misma manera, se requiere que el Smart TV tenga la capacidad para enviar información hacia uno o más Smartphones, al tiempo que recibe datos relacionados con las acciones que los usuarios ejecutan sobre las pantallas de sus dispositivos.

3.3.1.6. Comunicaciones de baja latencia

En términos generales, los usuarios de dispositivos móviles están acostumbrados a una respuesta rápida y fluída en las acciones que realizan sobre las pantallas de sus Smartphones. El uso de este tipo de equipos como dispositivos de interacción hacia la pantalla pública, traslada estas características al middleware de cooperación Smart TV - Smartphone. En consecuencia, para lograr una respuesta consistente durante la interacción de los usuarios es necesario garantizar un esquema de comunicaciones de baja latencia que mejore el desempeño del sistema y la tasa de intercambio de mensajes [115]. Esto se traduce en una mejora de la experiencia de usuario.

3.3.2. Alcance y restricciones de implementación

Durante la implementación del middleware se encontraron algunos requisitos adicionales con algunas restricciones para su implementación de acuerdo al alcance inicial definido y que se someten a consideración para trabajos futuros.

3.3. Middleware de cooperación Smart TV - Smartphone

3.3.2.1. Interoperabilidad

A pesar de que el middleware de cooperación Smart TV – Smartphone para un entorno de digital signage es diseñado con protocolos de comunicaciones abiertos e interoperables, sus interfaces de programación están limitadas al sistema operativo Android.

3.3.2.2. Escalabilidad

La implantación de un sistema de Digital Signage de gran escala con la capacidad de manejar grandes volúmenes de interacción con cientos o miles de Smartphones interactuando con otros cientos o miles de Smart TV se encuentra limitada tanto por las dimensiones físicas de la pantalla del Smart TV como también por las características hardware de los dispositivos de soporte, lo cual puede sugerir la utilización de técnicas de escalabilidad de carga tales como redundancia de servidores.

3.3.2.3. Seguridad

La seguridad y la privacidad de los datos es un requisito prevalente en los sistemas de información que debe ser abordado desde distintos frentes con diversas perspectivas [116]. Este requisito se considera un trabajo futuro en la versión actual del middleware.

3.3.2.4. Widgets adicionales

De acuerdo con la revisión del estado del arte en las áreas de interés para el proyecto de investigación se identificaron aproximaciones para la interacción Smart TV – Smartphone que hacen uso de un conjunto propio de widgets visuales que habilitan la interacción [116]. La versión actual del middleware no define widgets adicionales a los especificados por el sistema operativo Android. Su enfoque ha sido dirigido hacia la utilización de los gestos táctiles ya disponibles.

3.3.3. Arquitectura

La figura 3.2 muestra la arquitectura propuesta para el middleware que soporta el esquema de cooperación Smart TV - Smartphone. Como se puede observar, la arquitectura incluye una estructura en capas que evita el acoplamiento entre los principales componentes del sistema, al tiempo que facilita su mantenimiento y evolución sobre el tiempo. En términos generales, la capa inferior es soportada por el sistema operativo Android, especialmente en lo que se refiere a las capacidades de networking. Por otro lado, la capa superior despliega una API abierta que facilita el acceso a los servicios del middleware de una forma simple al abstractear las complejidades del modelo de comunicación y transferencia de mensajes. A continuación se realizará una breve descripción de cada una de las capas de la arquitectura.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

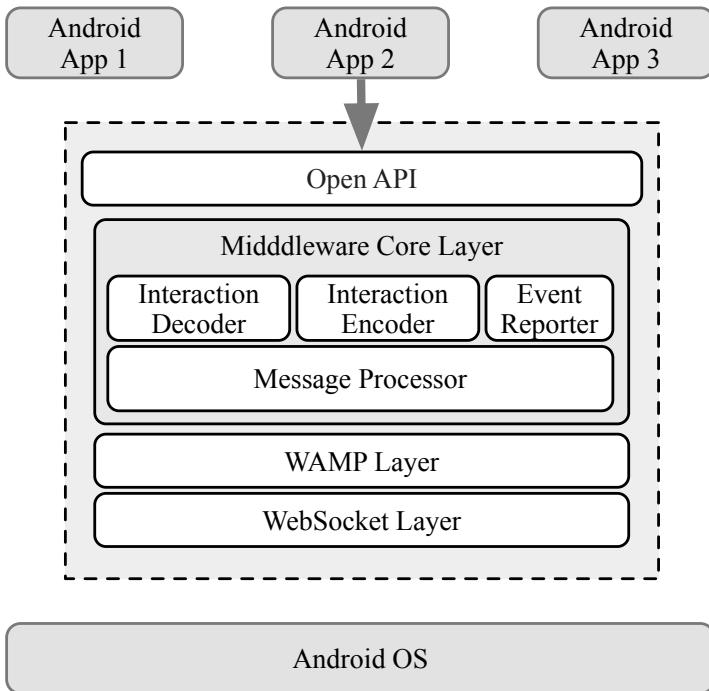


Figura 3.2: Arquitectura del middleware. Fuente Propia.

3.3.3.1. WebSocket layer

Se implementa una versión liviana del protocolo WebSocket con el objeto de lograr una comunicación bidireccional en tiempo real entre los Smartphones y el Smart TV. Actualmente, varios intentos para proporcionar comunicación en tiempo real sobre protocolos de Internet confían en técnicas no estandarizadas conocidas como Comet [117], las cuales se implementan sobre un protocolo sin estado como HTTP (el término sin estado hace referencia a que cada solicitud en HTTP es independiente una de la otra). Algunas de ellas como Polling, Long Polling o Streaming posponen la respuesta HTTP hasta que el servidor tiene algo para enviar hacia el cliente, dando la apariencia de una comunicación en tiempo real [118]. No obstante, este tipo de técnicas incrementan la sobrecarga de mensajes y por ende generan mayores niveles de latencia, lo cual restringe su aplicación en el desarrollo de un middleware con propósitos interactivos de acuerdo a los principios expuestos en la sección 3.3.1.

En su lugar, el protocolo WebSocket proporciona una comunicación full-dúplex a través de un canal de comunicaciones bidireccional que opera a través de un socket abierto sobre la Web, una característica deseable para construir sistemas escalables con requerimientos de baja latencia como es el caso del middleware propuesto [119]. Al reducir la sobrecarga de mensajes, la capa WebSocket proporciona un canal de comunicaciones bidireccional eficiente entre los diferentes dispositivos.

3.3. Middleware de cooperación Smart TV - Smartphone

3.3.3.2. WAMP layer

La propuesta de implementación presentada en esta arquitectura puede definirse como un middleware orientado a mensajes (MOM) que utiliza un paradigma de interacción Publisher/Subscriber. MOM es un tipo específico de middleware que soporta el intercambio de mensajes a través de un ambiente de aplicación distribuido; algunos de ellos aseguran la entrega de mensajes a través de gestión de colas y proporcionan servicios de soporte (directorio, seguridad, etc.). Por otro lado, el modelo Publisher/Subscriber es una paradigma popular de interacción en el cual el Publisher publica un mensaje a muchos consumidores a través de un canal virtual llamado *topic* o *tópico*. Así, los consumidores eligen un tópico de su interés y se suscriben al mismo, de tal manera que cualquier mensaje correspondiente a un tópico específico es entregado a todos sus suscriptores [120].

De acuerdo a la descripción realizada previamente, esta capa gestiona todas las complejidades relacionadas con el intercambio de mensajes usando un esquema de interacción Publisher/Subscriber. Con este propósito, se adoptó una implementación open source para Android del protocolo WAMP (Web Application Message Protocol), la cual fue adaptada para mejorar sus estabilidad [121]. Este protocolo, corresponde a una abstracción de alto nivel del protocolo WebSocket, lo cual garantiza que el intercambio de mensajes entre Publishers y Subscribers sea realmente asíncrono, al tiempo que mejora la eficiencia en la notificación de eventos hacia los Subscribers gracias a la reducción en la sobrecarga de mensajes que ofrece el protocolo como fue analizado previamente. El esquema de interacción será desglosado con mayor detalle cuando se presente el modelo de comunicaciones en la sección 3.3.4.

3.3.3.3. Middleware core layer layer

Esta capa actúa como una gateway para el intercambio de mensajes y gestiona el proceso de interacción de acuerdo a un modelo de comunicaciones bien definido. En términos simples, las acciones de los usuarios sobre las pantallas táctiles de los Smartphones son preprocesadas y luego preparadas en un formato específico de mensajes que son enviados a otros dispositivos. Igualmente, los mensajes entrantes son procesados y entregados a la aplicación correspondiente en el Smart TV a través de los servicios del API.

Especificamente, las funciones de esta capa se soportan en componentes más especializados que se describen a continuación:

- **Interaction Encoder:** Todos los eventos que tienen lugar en las pantallas táctiles de los Smartphones requieren de una apropiada codificación antes de ser publicados en el Smart TV, la cual es la principal función de este componente. En sentido estricto, las aplicaciones de los dispositivos móviles sensan los eventos y gestos que se producen en la pantalla, los cuales a su vez disparan eventos táctiles en el sistema tales como press, long press, tap, double tap, swipe, drag, move o un evento táctil personalizado.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

- **Message Processor:** Este componente es responsable del envío y recepción de los mensajes que intercambian los dispositivos a través del WAMP Broker. En términos generales, los eventos táctiles codificados son publicados en los *topics* correspondientes; posteriormente, el WAMP Broker define el destino final de los mensajes de acuerdo a los suscriptores existentes en los *topics*. Finalmente, este componente recibe los mensajes entrantes de forma codificada y los entrega al Interaction Decoder.
- **Interaction Decoder:** Este componente es responsable de la decodificación de todos los mensajes entrantes con el objeto de reconstruir apropiadamente la información del evento táctil original. Los eventos táctiles reconstruidos son entregados a las aplicaciones de terceros a través de los métodos de notificación disponibles en la API del middleware.
- **Event Reporter:** Este componente es responsable de la recolección de información relacionada con la ejecución de los procesos del middleware y las interacciones realizadas por los usuarios. La información de ejecución del middleware se refiere a los datos del comportamiento en tiempo de ejecución como alertas, advertencias, errores o bloqueos de los componentes en las distintas capas que pueden ser relevantes para los desarrolladores de aplicaciones. La información de las interacciones realizadas por los usuarios se refiere a los mensajes de interacción que se están intercambiando, la cantidad de usuarios que interactúan y la forma en que lo hacen. Estas funciones fueron concebidas con propósitos de gestión para un entorno de digital signage. Por ejemplo, a través de esta información se podría inferir el grado de aceptación de una campaña publicitaria o el set de anuncios preferido por los consumidores de un centro comercial.

3.3.3.4. Open API

El middleware expone una API abierta para proporcionar acceso a sus servicios a los desarrolladores de aplicaciones. Esta API abstracta las complejidades realacionadas con el modelo de comunicaciones implementado. Específicamente, en el diseño y construcción del API se utilizaron un conjunto de patrones reconocidos en la industria del software [122], tales como:

- **Factory:** Permite la creación de instancias de mensajes o de clientes de comunicación.
- **Observer:** Habilita la notificación de eventos relacionados con el estado de las conexiones, el intercambio de información y el control de los dispositivos.
- **Singleton:** Facilita la identificación de las interacciones de los usuarios sobre la pantalla de los Smartphones.

Es importante resaltar que de acuerdo a las restricciones analizadas en la sección 3.3.2, el diseño del API no contempla la implementación de widgets adicionales a los ya existentes en el sistema operativo Android. En este orden de ideas, el principal propósito del API consiste en la abstracción de los procesos de los componentes de las capas inferiores del middleware, especialmente en lo correspondiente al modelo de comunicaciones.

3.3. Middleware de cooperación Smart TV - Smartphone

La figura 3.3 muestra un diagrama de clases de alto nivel que ilustra las principales funcionalidades proporcionadas por el API. A continuación, se realiza una breve descripción de las clases e interfaces principales:

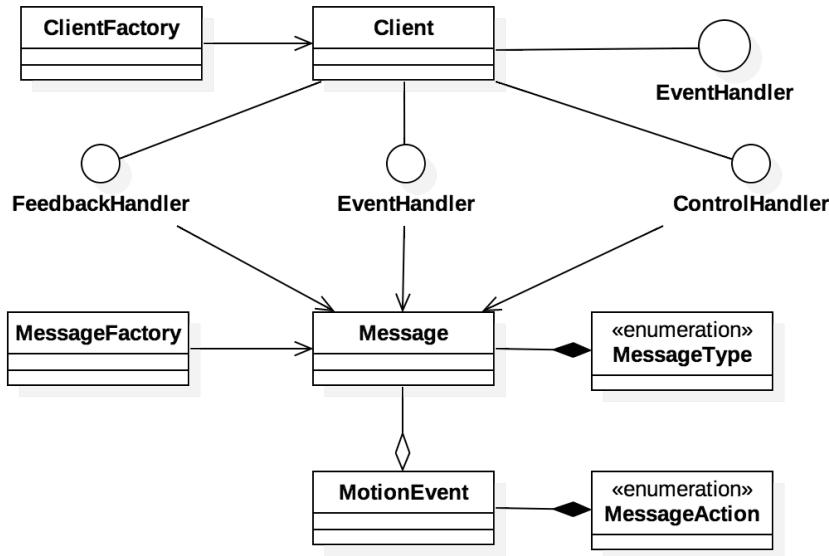


Figura 3.3: Middleware API. Fuente Propia.

- **Client:** Corresponde a la clase principal que habilita un punto de entrada para establecer una conexión con el WAMP Broker. Así mismo, soporta los procesos de publicación y suscripción a los diferentes tópicos.
- **ClientFactory:** A través de la implementación del patrón Factory habilita la creación de objetos Client de acuerdo a parámetros específicos.
- **ConnectionHandler:** Esta interface define métodos de *callback* para gestionar las notificaciones acerca de eventos de conexión hacia el WAMP Broker.
- **EventHandler:** Esta interface define métodos de *callback* para gestionar las notificaciones acerca de eventos de interacción sobre las pantallas táctiles de los Smartphones.
- **ControlHandler:** Esta interface define métodos de *callback* para gestionar las notificaciones acerca de eventos de control desde los Publishers y los Subscribers.
- **FeedbackHandler:** Esta interface define métodos de *callback* para gestionar las notificaciones acerca de eventos publicados en el tópico de Feedback. A través de este tópico se habilita la entrega de información complementaria a los suscriptores de un tópico particular.
- **Message:** Esta clase encapsula la estructura del contenido de los mensajes intercambiados entre los Clients (Publishers/Subscribers) y el WAMP Broker.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

- **MessageFactory:** A través de la implementación del patrón Factory habilita la creación de objetos Message de acuerdo a parámetros específicos.

3.3.4. Modelo de comunicaciones

Como se mencionó anteriormente, el middleware propuesto es un middleware orientado a mensajes que utiliza el paradigma Publisher/Subscriber, ampliamente utilizado en otros dominios como SOA (Software Oriented Architecture), ESB (Enterprise Service Bus) y EDA (Event Driven Architecture) [123]. Bajo este modelo, el Publisher publica los mensajes de tópicos específicos en el broker para que puedan ser consumidos por los Subscribers. Así, el broker asegura la entrega de los mensajes puesto que un mensaje no es borrado hasta que todos los suscriptores de un tópico específico hayan recibido la información; esto asegura un modelo de comunicaciones liviano para todos los clientes conectados (Figura 3.4). A continuación se hará un mayor énfasis en el modelo de interacción diseñado bajo este paradigma de funcionamiento y el protocolo de comunicaciones diseñado para tal fin.

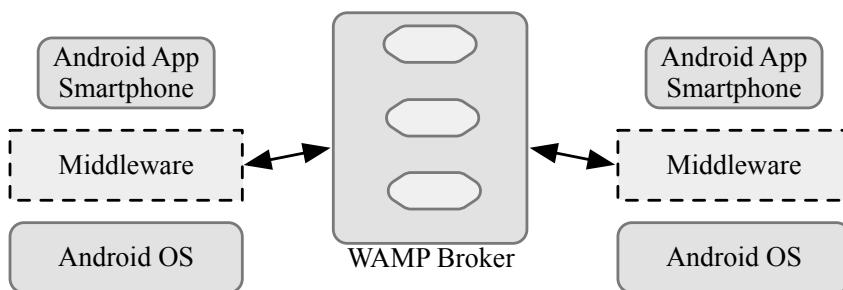


Figura 3.4: Modelo de comunicaciones Publisher/Subscriber para el middleware. Fuente Propia.

3.3.5. Modelo de interacción

En términos simples y de acuerdo a la filosofía de funcionamiento del paradigma Publisher/Subscriber, los Smartphones actúan como Publishers que publican datos sobre las acciones de los usuarios en la pantalla en tópicos específicos en el WAMP Broker. Al mismo tiempo, el Smart TV se suscribe a dichos tópicos para recibir los mensajes de todos los clientes conectados (Figura 3.5).

No obstante, en los entornos de Digital Signage no es suficiente con gestionar solamente la información derivada del proceso de interacción como tal; frecuentemente, la pantalla pública necesita mayor información sobre los dispositivos circundantes. Por ejemplo, ¿Cuántos dispositivos están conectados?, ¿Cuándo un Smartphone está listo para publicar mensajes en un tópico específico? ¿Cuándo se ha producido una desconexión del Smartphone?. El modelo propuesto ha destinado un tópico específico (control) para el manejo de este tipo de información, donde el Smart TV y los Smartphones pueden compartir mensajes de control

3.3. Middleware de cooperación Smart TV - Smartphone

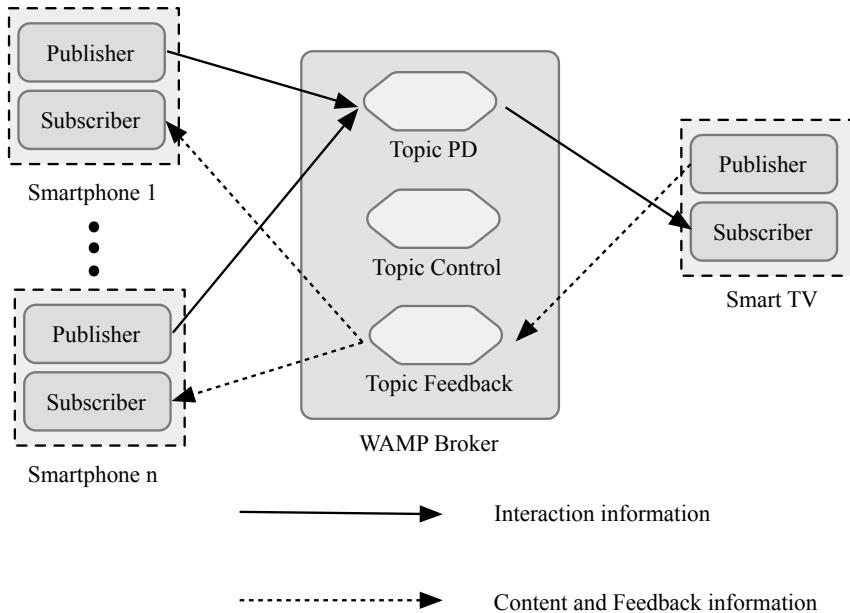


Figura 3.5: Modelo de interacción para el middleware. Fuente Propia.

especiales. Así mismo, este mecanismo habilita a los desarrolladores de aplicaciones para implementar estructuras de control más complejas cuando así se requiera.

Por otro lado, en algunos escenarios el Smart TV en su rol de pantalla pública, puede requerir compartir información con un dispositivo o un grupo de dispositivos en particular. De una manera similar al caso anterior, el middleware proporciona un tópico especial (feedback) para intercambiar información complementaria que no está relacionada con los mensajes de interacción o los mensajes de control. Por ejemplo, a través de este tópico se podría transportar la reseña de una película en particular cuando la pantalla pública está desplegando una lista de películas, lo cual corresponde a información complementaria que ayuda a mejorar la comprensión y asimilación del contenido por parte del usuario.

Finalmente, para hacer más claro el modelo de interacción del middleware que soporta el modelo de cooperación Smart TV - Smartphone se plantea el siguiente ejemplo: en el contexto del piloto desarrollado, el cual será descrito con mayor detalle en el capítulo 5, una lista de anuncios publicitarios es desplegada en el Smart TV. La aplicación cliente disponible en los Smartphones de los usuarios permite utilizar el gesto *Swipe* para moverse de un anuncio a otro en la pantalla pública, mientras el gesto *Tap* permite enviar datos complementarios sobre el anuncio elegido en la pantalla pública, para ser desplegados en la pantalla del Smartphone. La figura 3.6 muestra los procesos involucrados en cada uno de los componentes de la arquitectura para el intercambio de información en el escenario de ejemplo propuesto.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

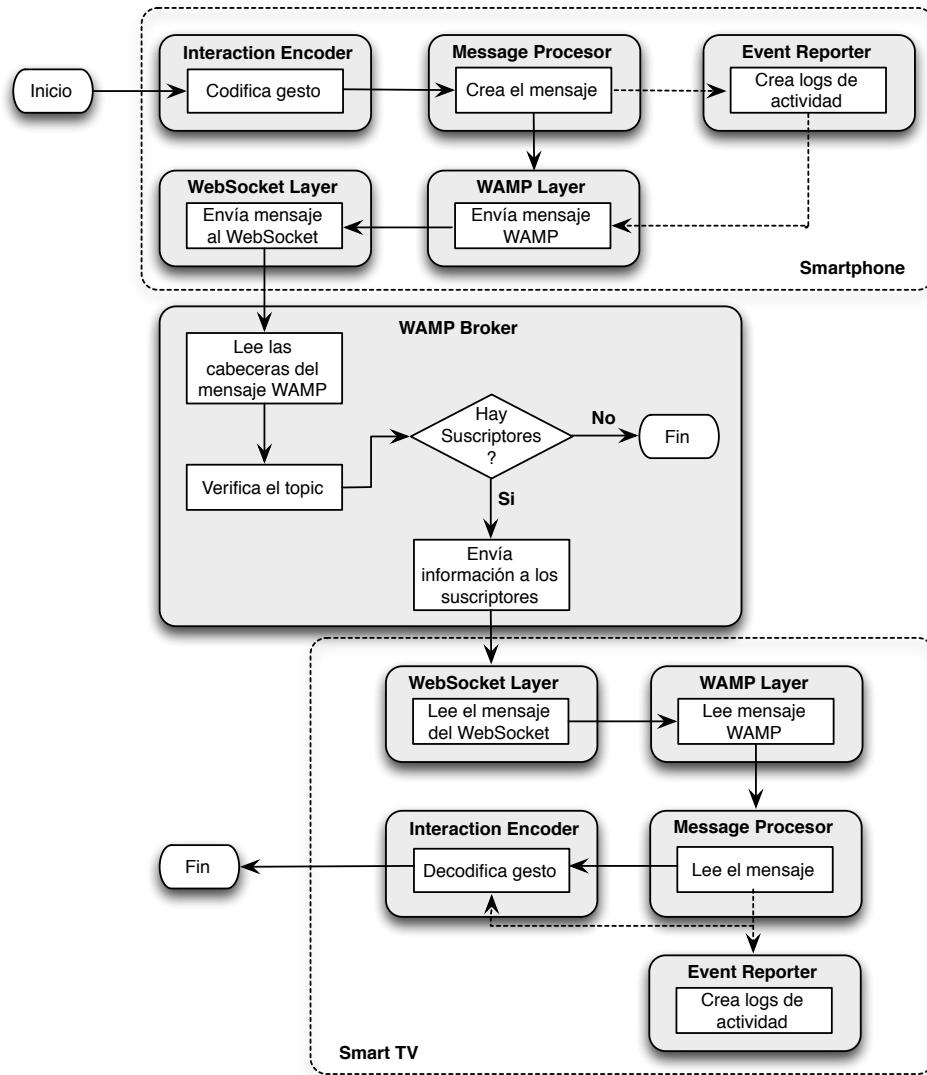


Figura 3.6: Modelo de interacción - intercambio de información. Fuente Propia.

3.3. Middleware de cooperación Smart TV - Smartphone

3.3.6. Protocolo de comunicaciones

El middleware que soporta el modelo de cooperación Smart TV - Smartphone propone un protocolo bien definido para habilitar el intercambio de mensajes de acuerdo al funcionamiento del paradigma Publisher/Subscriber anteriormente descrito. En términos generales, los toques o gestos que realizan los usuarios sobre la pantalla de los Smartphones se representan a través de objetos *MotionEvent* cuya estructura se muestra en la tabla 3.1. En este sentido, un sólo objeto MotionEvent es suficiente para representar eventos simples como un *Tap*, mientras que otros gestos más complejos como un *Swipe* o un *Drag* requieren de la combinación de varios de ellos.

MotionEvent		
Campo	Tipo	Descripción
Id	Integer	Identificador de la fuente del evento.
Action	Enum: MessageAction	Enumeración que identifica el tipo de acción con alguno de los siguientes posibles valores: Action Down, Action Up, Action Move, Action Cancel, Init o End.
x	Integer	Valor de la coordenada x de la acción realizada relativa al sistema de coordenadas del dispositivo móvil.
y	Integer	Valor de la coordenada y de la acción realizada relativa al sistema de coordenadas del dispositivo móvil.
EventTime	Long	Duración de la acción realizada medida en milisegundos.
DownTime	Long	Marca de tiempo del primer evento generado dentro de un flujo de eventos que componen un gesto complejo del cual este evento hace parte.
Source	Integer	Fuente del evento de acuerdo con las especificaciones del sistema operativo Android.

Tabla 3.1: Estructura objeto *MotionEvent*

Los objetos MotionEvent son serializados utilizando una representación JSON (Java Script Object Notation), para luego ser encapsulados en estructuras de mensajes denominadas *Message*, cuyos componentes se ilustran en la tabla 3.2.

Message		
Campo	Tipo	Descripción
Uuid	String	Identificador de la fuente del evento.
Type	Enum: MessageType	Enumeración que identifica el tipo de mensaje con alguno de los siguientes posibles valores: Move, Press, Long Press, Tap, Double Tap, Swipe, Drag, Custom, Setup, Ping, Bye o Feedback.
StartContent	String	Campo utilizado como payload para transportar datos arbitrarios del dominio de la sistema o MotionEvents serializados.
EndContent	String	Campo utilizado como payload para transportar datos arbitrarios del dominio de la sistema o MotionEvents serializados.
Extras	String	Campo utilizado como payload para transportar datos serializados adicionales o datos binarios serializados.
Timestamp	Long	Marca de tiempo de creación del mensaje.

Tabla 3.2: Estructura de mensajes del protocolo.

Capítulo 3. Esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua

De otra parte, la figura 3.7 muestra el proceso de encapsulamiento realizado por el protocolo de comunicaciones para el intercambio de mensajes entre Publishers y Subscribers a través del WAMP Broker. En términos simples, los objetos MotionEvent se encapsulan en estructuras Message, las cuales son serializadas a través de representaciones JSON que hacen parte del contenido de una trama del protocolo WAMP, que a su vez hace parte del contenido de una trama del protocolo WebSocket.

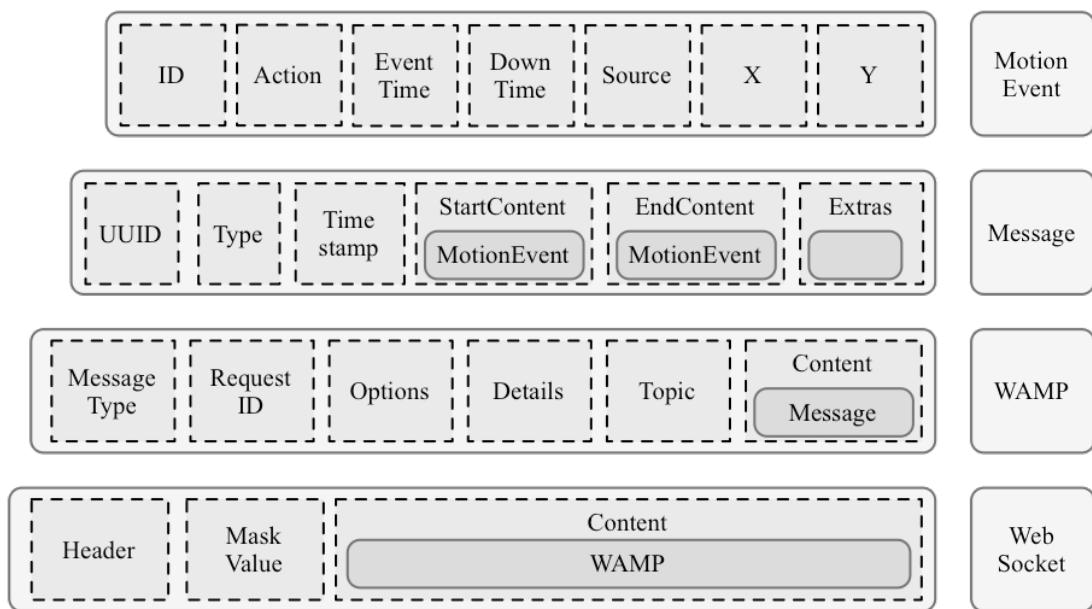


Figura 3.7: Protocolo de comunicación - encapsulamiento. Fuente Propia.

Finalmente, a manera de ejemplo la figura 3.8 muestra la representación en formato JSON para el gesto *Swipe* (acción de deslizar el dedo rápidamente sobre la pantalla del Smartphone). El formato utilizado es similar para otros gestos como *Press*, *Long Press*, *Tap*, *Double Tap*, *Drag* o *Move*.

3.3. Middleware de cooperación Smart TV - Smartphone



Figura 3.8: Representación JSON para el gesto Swipe. Fuente Propia.

```
{  
  "uuid": "e430492a-2eaa-4cd7-9cf1-af5df7808501",  
  "type": "SWIPE",  
  "startContent": {  
    "action": "ACTION_DOWN",  
    "downTime": 40929359,  
    "eventTime": 40929724,  
    "id": 3,  
    "source": 4098,  
    "x": 114.8405,  
    "y": 1036.1904  
  },  
  "endContent": {  
    "action": "ACTION_UP",  
    "downTime": 40929359,  
    "eventTime": 40929359,  
    "id": 3,  
    "source": 4098,  
    "x": 292.59363,  
    "y": 1064.49493  
  },  
  "extras": "null",  
  "imestamp": 1418335248056
```


Capítulo 4

Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

De acuerdo a los planteamientos presentados en el capítulo 3, las contribuciones de la presente investigación no sólo se centran en la construcción de un modelo de cooperación Smart TV - Smartphpne que mejora las características de despliegue de las recomendaciones de anuncios en un entorno de publicidad ubicua (específicamente Digital Signage), sino también en la construcción de un sistema de recomendaciones que incorpora información de confianza como una de las variables contextuales más relevantes a tener en cuenta cuando se piensa en la implementación de técnicas publicitarias tan difundidas como el *word of mouth*.

El presente capítulo describe los aspectos más relevantes relacionados con la construcción del sistema de recomendaciones, el cual utiliza un filtrado colaborativo que incorpora información de confianza que se infiere de la red social de los usuarios, más específicamente de la red social Facebook. En primera instancia, se realiza una conceptualización inicial alrededor de la *confianza* para luego describir el algoritmo que realiza el proceso de inferencia. Posteriormente, se describe el algoritmo que modifica el filtrado colaborativo clásico para incorporar la información de confianza inferida. Finalmente, se describe el modelo de evaluación definido para medir el balance precisión/novedad de esta nueva aproximación y se desglosan las técnicas de agregación utilizadas para las recomendaciones grupales. Con respecto a este último aspecto, es importante aclarar que de acuerdo a los objetivos del presente trabajo, la utilización de técnicas de agregación con fines de recomendación grupal hace parte de la implementación del esquema de cooperación multipantalla con fines de mejora en el balance precisión/novedad al momento del despliegue de los anuncios; la definición de nuevas técnicas de agregación o una adaptación de las mismas, se encuentra fuera del alcance de la presente investigación y se considera como parte de los trabajos futuros.

4.1. La confianza en entornos de publicidad ubicua

De acuerdo a lo planteado en el capítulo anterior, específicamente en la sección 3.1, una de las motivaciones más importantes para la presente investigación tiene que ver con la posibilidad de enriquecer el sistema de recomendaciones en un entorno de publicidad ubicua (específicamente Digital Signage) con información contextual que tenga un impacto relevante no solamente para los clientes potenciales sino también para los advertisers.

No obstante, la inclusión de información contextual en un sistema de recomendaciones puede resultar bastante compleja si se tiene en cuenta la gran cantidad de variables que pueden influir en un contexto publicitario (posición, temperatura, temporada del año, preferencias, etc.) A partir de las reflexiones planteadas en el desarrollo de la presente investigación, se concluye que una aproximación colaborativa a partir de la información que aportan los diferentes usuarios del sistema es una característica deseable en entornos de publicidad ubicua, pero su verdadero impacto debe ir más allá de la implementación clásica para incluir información de confianza; como se dijo anteriormente, [110] y [111] demostraron que las personas tienden a dar más credibilidad a las recomendaciones de individuos en los que ellos confían y esa es la base del *word of mouth*, una técnica publicitaria ampliamente reconocida y que fue descrita en el capítulo anterior (sección 3.1). En este sentido, la confianza en otros usuarios es la variable contextual en la cual se ha centrado el foco del presente trabajo.

Sin embargo, el dominio de la publicidad ubicua demanda la presencia de mecanismos más implícitos que explícitos, lo cual significa que la inclusión de confianza en el sistema de recomendaciones depende en gran medida de que esta variable sea algo cuantificable que se pueda *inferir*, más que algo cuantificable por lo que se deba *preguntar* a los usuarios. En ese orden de ideas, el presente trabajo define un mecanismo de inferencia de confianza a partir de la información del círculo social más cercano del usuario, datos que hoy por hoy hacen parte de diversas redes sociales. Esta aproximación será descrita con mayor detalle en la sección 4.2.

De acuerdo a los planteamientos anteriores, es importante entender que la confianza está fuertemente relacionada con el concepto de *homofilia*, un principio que postula que las personas tienden a formar lazos con otros individuos que tienen características similares [124]. En su sentido más básico, esta definición puede sugerir que la inferencia de confianza se reduce a un análisis de relaciones binario en el cual se determina una condición de *amigo* o *no-amigo*. No obstante, esta aproximación no es suficiente cuando se trata de inferir la confianza entre dos individuos como se ilustra en el siguiente ejemplo: el *Usuario A* y el *Usuario B* son amigos; el *Usuario B* y el *Usuario C* también son amigos, pero el *Usuario A* y el *Usuario C* son sólo conocidos. Días después, el *Usuario C* envía una solicitud de amistad al *Usuario A*; cuando éste la acepta, el *Usuario A* y el *Usuario C* se encuentran ahora conectados como amigos. Desde la perspectiva de este análisis binario, no existe diferencia

4.2. Inferencia de confianza a partir de las redes sociales

entre las relaciones que el *Usuario A* mantiene con *B* y *C*, aunque esta condición no refleje con exactitud lo que sucede en la práctica.

En realidad, la inferencia de confianza es un mecanismo que va más allá de un análisis simple de la condición de *amigo* o *no-amigo*. Es así como a partir de la teoría del análisis de redes sociales, surge un nuevo concepto que complementa satisfactoriamente esta aproximación con miras a los requerimientos de inferencia que se plantean en un entorno de publicidad ubicua: la *fortaleza de los vínculos* o *tie strength*. En términos simples, esta característica es una cuantificación de que tan fuerte es la relación entre dos personas cuando existe un vínculo entre ellos; así, dos tipos de vínculos podrían ser inferidos: *vínculos fuertes - strong ties* (amigos) o *vínculos débiles - weak ties* (conocidos) [125]. Bajo este análisis, se asume que la *fortaleza de los vínculos* es un indicador directo de la confianza que puede existir entre dos individuos.

A partir de las reflexiones anteriores, es claro que se requiere un mecanismo implícito para la inferencia de confianza entre individuos que además supere las expectativas de un simple análisis binario para incorporar información sobre la fortaleza de los vínculos. No obstante, el estudio de estos requerimientos sugiere la resolución de los siguientes interrogantes: ¿Qué información se debe utilizar para inferir la fortaleza de los vínculos? ¿Cómo cuantificar la fortaleza de los vínculos en una escala adecuada que pueda incorporarse al algoritmo de recomendación? En la siguiente sección se describirá el mecanismo de inferencia de confianza propuesto, abordando así la solución a los planteamientos anteriores.

4.2. Inferencia de confianza a partir de las redes sociales

Aunque la información presente en los perfiles de los usuarios que son almacenados en diversas plataformas pueden proporcionar algún nivel de información sobre las similitudes que pueden existir entre las personas, las investigaciones previas han demostrado que los datos asociados a las *interacciones* entre los individuos son una de las fuentes más importantes al momento de inferir el grado de fortaleza de los vínculos entre las personas. En este sentido, diversas técnicas podrían ser aplicadas para inferir este tipo de información: la reciprocidad de llamadas entre dos usuarios de teléfonos móviles, el número de tweets entre usuarios de Twitter o el intercambio de e-mails entre los individuos [125].

No obstante, las redes sociales proporcionan un espacio mucho más rico para tratar de inferir información sobre la confianza que existe entre las personas a través de un amplio conjunto de interacciones disponibles, lo cual puede representar una radiografía más precisa sobre el mapa de las relaciones que existen entre los individuos. En este sentido, aunque otras investigaciones han construido redes sociales propietarias para sus experimentos, el presente trabajo ha tomado como referencia una red pública como Facebook para desarrollar una aproximación para la inferencia de confianza entre individuos. El uso de Facebook

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

procura el diseño de una solución más escalable no sólo en el dominio de la publicidad ubicua sino también en otros dominios, gracias a su popularidad y aceptación entre millones de usuarios.

Como punto de partida, la presente investigación retoma el trabajo de [73], en el cual los autores presentan un modelo predictivo que relaciona datos de la red social con la fortaleza de las relaciones entre individuos usando un dataset de cerca de 2.000 vínculos, con el objeto de distinguir entre lazos fuertes y lazos débiles. La tabla 4.1 muestra un resumen del modelo para las diferentes variables agrupadas en categorías.

Adicionalmente, el modelo propuesto define un top de 15 variables a partir de las cuales se puede inferir información de confianza con mayor precisión. Para el propósito de la presente investigación, se compara este top con otros trabajos similares para obtener un conjunto unificado de variables que sirva como punto de partida para el estudio (Figura 4.1). De acuerdo a este análisis, se seleccionaron 7 variables para iniciar la construcción del algoritmo de inferencia de confianza entre dos usuarios A y B. Las variables seleccionadas se muestran en la tabla 4.2.

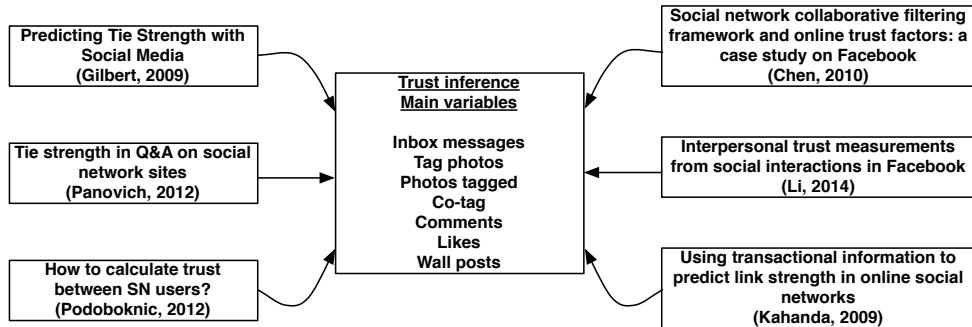


Figura 4.1: Estado del arte: inferencia de confianza a partir de las interacciones entre usuarios.
Fuente Propia.

Con base en los elementos anteriores, se define una primera aproximación para el algoritmo de inferencia, teniendo en cuenta que el objetivo es construir una ecuación que combine la contribución de todo el conjunto de variables para generar como resultado un score de confianza que luego será integrado al algoritmo de filtrado colaborativo del sistema de recomendaciones; igualmente, la idea es mantener esta aproximación tan simple como sea posible para disminuir el impacto sobre el rendimiento del sistema. De esta forma, dado que la confianza entre dos individuos no es necesariamente simétrica, tomando como base el trabajo de [71] y de acuerdo a la teoría de Utilidad de Atributos Múltiple (MAUT, por sus siglas en inglés), se define la confianza que un usuario A tiene en un usuario B de acuerdo a la siguiente expresión:

$$T_{A,B} = \alpha \frac{\sum IM}{totIM} + \beta \frac{\sum Likes}{totLikes} + \gamma \frac{\sum TagsTo}{totTagsTo} + \delta \frac{\sum TagsFrom}{totTagsFrom} + \xi \frac{\sum Cotags}{totCotags} + \theta \frac{\sum C}{totC} + \phi \frac{\sum WP}{totWP} \quad (4.1)$$

4.2. Inferencia de confianza a partir de las redes sociales

Social variables	
Intensity	Wall words exchanged
	Wall posts
	Inbox messages exchanged
	Status updates
	Comments
	Likes
Intimacy	Tags
	Number of friends
	Days since last communication
	Wall and inbox intimacy words
	Appearances together in photos
Duration	Distance between hometowns
	Relationship status
	Days since first communication
Reciprocal services	Links exchanged by wall post
	Applications in common
	Mutual friends
Structural	Groups in common
	Similarity of interests
	Common networks
	Number of positive words
Emotional support	Number of negative words
	Gifts exchanged
	Age difference
Social distance	Occupations difference
	Educational difference
	Political and religious difference
	Gender
Demographic	Number of apps installed
	Number of inbox messages
	Number of wall posts
	Number of photo's comments

Tabla 4.1: Modelo predictivo para datos de medios sociales. Fuente [73].

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

Set inicial de variables para inferencia de confianza

- Exchanged inbox messages
- Likes (from B to A)
- Tags to B
- Tags from B
- Cotags (posts where both users are tagged together)
- Comments (from B to A)
- Wall posts (from B to A)

Tabla 4.2: Primer conjunto de variables para inferir confianza desde Facebook. Fuente propia.

Donde $\alpha + \beta + \gamma + \delta + \xi + \theta + \phi = 1$. IM hace referencia a los mensajes intercambiados en el inbox, C a los Comentarios, WP a los posts en el muro (Wall posts) y el prefijo *tot* hace referencia al total de interacciones para un atributo en particular, por ejemplo la cantidad total de mensajes intercambiados en el inbox por un usuario específico con todos sus amigos. La normalización que tiene lugar al dividir entre el total de interacciones, tiene sentido cuando consideramos la frecuencia de interacción entre individuos como un claro indicador de confianza. Para comprenderlo mejor, se bosqueja el siguiente ejemplo: se supone que el usuario A tiene el número de interacciones que se ilustra en la figura 4.2 con los usuarios B y C. A simple vista, se podría intuir que A confía más en C que en B, pero probablemente esta condición se deba a que C es un usuario más activo que B, luego el nivel de actividad en la red es un parámetro que debería ser tenido en cuenta. Si se asume que B tiene un total de 5 interacciones con sus amigos y C un total de 10 interacciones, cuando se aplica la normalización se observa que casi el el 60 % (3/5) de las interacciones de B se producen con el usuario A, mientras que éstas sólo representan el 40 % (4/10) para el usuario C. Esto significa que la condición de *usuario activo* tiene un efecto importante en el proceso de inferencia, luego es importante tener una visión global de la actividad de los usuarios en la red, en lugar de enfocarse en la actividad de pares específicos. Otros trabajos han usado aproximaciones similares que sugieren la necesidad de realizar la normalización propuesta [72], [76].

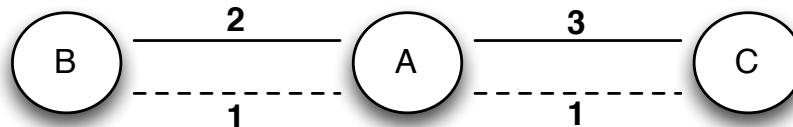


Figura 4.2: Interacción de usuarios en una red social. Fuente Propia.

Una vez definida una primera aproximación para el algoritmo de inferencia de confianza, uno de los retos más importantes planteados en la ecuación 4.1 es una estimación correcta de los pesos de cada variable. En la práctica, esta tarea no resulta trivial al punto que varias propuestas han realizado estimaciones empíricas que terminan definiendo pesos subjetivos durante la experimentación [126]. Aunque ésta pueda ser una propuesta aceptable, para el

4.2. Inferencia de confianza a partir de las redes sociales

contexto del presente trabajo se busca un mecanismo que permita combinar variables que se encuentren correlacionadas entre sí; por ejemplo, un tag puede provocar un *comentario* o un *like*, así que el número de interacciones de estas variables guarda una relación entre sí. De acuerdo a lo anterior, se decide adaptar el método sugerido por [76], el cual aplica la técnica de PCA (Principal Component Analysis). En términos simples, PCA usa una transformación ortogonal para convertir un conjunto de observaciones de variables posiblemente relacionadas, en un conjunto de valores de variables no relacionadas, al encontrar un conjunto reducido de combinaciones lineales para los tipos de interacción en este caso. Como resultado, se obtienen pesos para cada componente independiente, lo cual define la contribución de cada tipo de interacción de una forma más objetiva, simplificando a su vez el proceso de cálculo para la obtención de los pesos de cada variable. En este orden de ideas, a continuación se resume el proceso para calcular el score de confianza para cada uno de los amigos de un usuario específico:

- (1) Cálculo de la matriz de interacción: para cada amigo j de un usuario i ($j \in F_i$), se define un vector \vec{S}_{ij} , de tal manera que cada fila representa la interacción entre un amigo j y el usuario i y cada columna representa un tipo de interacción específico ($|F_i|$ filas y 7 columnas, una por cada variable de interacción). Posteriormente, la matriz es normalizada de acuerdo al análisis realizado previamente.
- (2) Cálculo de la matriz de covarianza: durante esta fase, se calculan las posibles relaciones entre las variables. Al final, se seleccionan los eigenvectores que corresponden a los eigenvalores más altos, para así obtener una combinación lineal de componentes principales como sigue:

$$T_j = \sum_{i=1}^m \frac{\lambda_i}{\sum \lambda_m} \times u_i \times Z_{ij} \quad (4.2)$$

$$Z_{ij}^k = \frac{s_{ij}^k - \bar{x}^k}{v^k}, \quad \bar{x}^k = \frac{\sum x^k}{|F_i|}, \quad v^k = \sqrt{\frac{\sum (s_{ij}^k - \bar{x}^k)^2}{|F_i| - 1}} \quad (4.3)$$

- (3) Cálculo del score de confianza: el score de confianza se calcula en dos pasos:

- (a) Se obtiene un score inicial a partir de la contribución de cada componente principal (ecuaciones 4.2 y 4.3).
- (b) A continuación se normaliza el valor obtenido en el paso anterior para desplazarlo a una escala entre -1 y 1 (ecuación 4.4); esto facilita la integración del score de confianza en el algoritmo de recomendación como se verá más adelante en la sección 4.3.

$$Trust score = \frac{(PCA_{score} - PCA_{min}) \times (Score_{max} - Score_{min})}{PCA_{max} - PCA_{min}} + Score_{min} \quad (4.4)$$

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

Una vez definida una primera aproximación para calcular un score de confianza entre usuarios a partir de la información sobre sus interacciones en la red social, se realiza una validación final para incluir la percepción de usuarios reales sobre el rol de cada una de las variables consideradas durante el proceso de inferencia. Con este propósito, se diseña una encuesta dirigida a 57 voluntarios de la empresa SmartSoft Play. Durante el procedimiento, se solicita a los usuarios que seleccionen las variables que a su criterio representan de mejor manera la confianza que se puede tener en otra persona en Facebook; al aplicar la encuesta se simplifica el conjunto de variables a 5 (todas las variables relacionadas con tags, simplemente se representan como tags). La figura 4.3 muestra los resultados obtenidos sobre un total de 145 votos para las 5 variables.

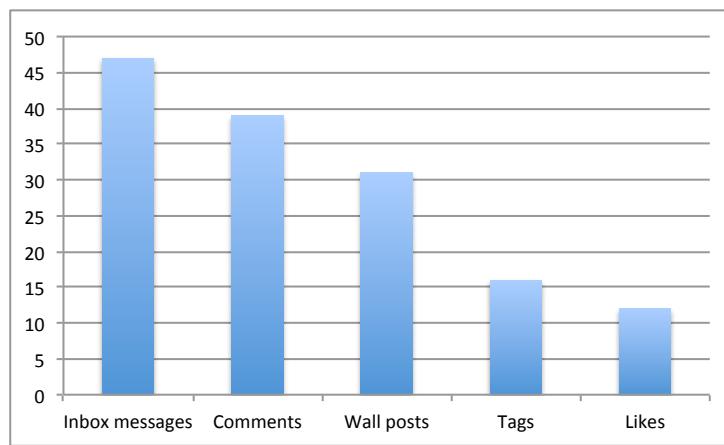


Figura 4.3: Validación del conjunto de variables para inferencia de confianza. Fuente Propia.

A partir de estos resultados, se puede observar que los mensajes en el inbox (*inbox messages*), los comentarios (*comments*) y los posts en el muro (*wall posts*) son las variables que los usuarios más relacionan con la *confianza* hacia otro individuo. Tomando como base esta percepción, se diseña un test de *ground truth* para calcular la precisión del algoritmo de inferencia de confianza de la siguiente manera:

- (1) Para cada participante, se calcula el listado de los 10 amigos con los que existe un vínculo de confianza más fuerte (*top ten*) usando en primera instancia el algoritmo de inferencia que incluye las siete variables definidas inicialmente; en una segunda instancia, se realiza el mismo cálculo pero reduciendo el número de variables de acuerdo a la percepción de los usuarios capturada en la encuesta.
- (2) Posteriormente, se solicita a los usuarios que elaboren un listado con su propio *top ten*, es decir con los 10 amigos en Facebook con los que perciben un vínculo de confianza más fuerte, ordenando la lista de mayor a menor.
- (3) Finalmente, se comparan los resultados del algoritmo (aplicando sus dos instancias) con el listado elaborado por cada uno de los participantes. Específicamente, se realiza una sustracción entre las posiciones entregadas por el algoritmo y el listado de los

4.2. Inferencia de confianza a partir de las redes sociales

participantes, se suman estas diferencias y se obtiene un promedio a partir del cual se procede a realizar el cálculo del porcentaje de precisión respectivo. Específicamente, el porcentaje de error se calcula como la relación entre el promedio obtenido en el ranking y la diferencia de error máxima que se puede obtener. Esta diferencia se obtendría si el algoritmo ordenara a los amigos en un orden totalmente inverso de confianza (el número 1 en la posición 10, el número 2 en la posición 9 y así sucesivamente); la suma de las diferencias en estos posicionamientos da como resultado 50. A manera de ilustración, la figura 4.4 muestra un ejemplo simple para el cálculo del porcentaje de precisión.

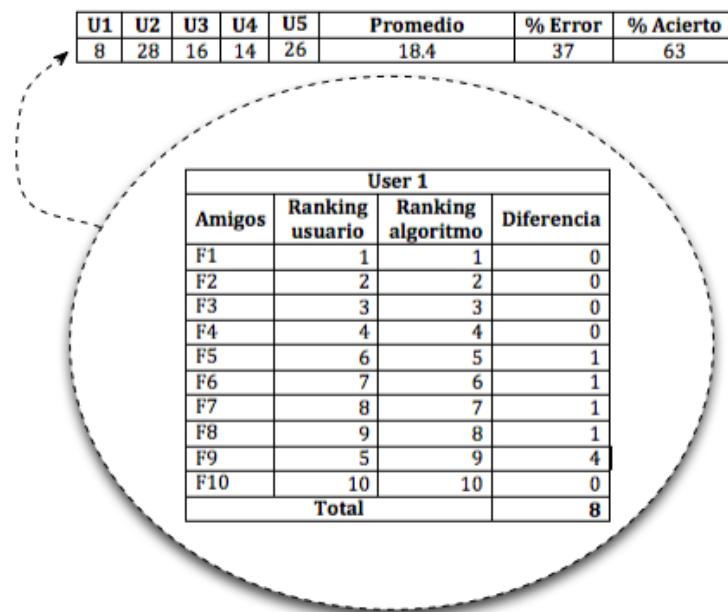


Figura 4.4: Cálculo de porcentaje de precisión del algoritmo de inferencia. Fuente Propia.

En síntesis, la segunda instancia del algoritmo de inferencia de confianza usando los mensajes en el *inbox*, los *comentarios* y los *posts* en el *muro*, demostró un mejor comportamiento que la versión original de acuerdo a la prueba de *ground truth*. No obstante, se decide realizar una nueva inspección incluyendo la contribución de los *tags*. En la tabla 4.3 se detallan los resultados obtenidos.

Test	Variables	Método	Promedio	Precisión
1	Inbox messages, comments, wall posts	PCA	18.4	63 %
2	Inbox messages, comments, wall posts, tags to	PCA	17.6	65 %

Tabla 4.3: Resultados de la prueba de ground truth para el algoritmo de inferencia de confianza. Fuente propia.

Como se puede observar, en principio la inclusión de información sobre los tags introduce una mejora de dos puntos porcentuales, que aunque no es significativa ($p = 0.493$)

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

posiciona el valor de precisión del algoritmo en un punto aceptable (cerca del 65 %), teniendo en cuenta el grado de subjetividad intrínseco que introduce la percepción de los usuarios. De acuerdo a lo anterior, finalmente el algoritmo realiza la inferencia de confianza a partir de cuatro variables de interacción como se muestra en la ecuación 4.5, lo cual reduce la cantidad de recursos computacionales requeridos durante el proceso.

$$T_{A,B} = \alpha \frac{\sum IM}{totIM} + \gamma \frac{\sum TagsTo}{totTagsTo} + \theta \frac{\sum C}{totC} + \phi \frac{\sum WP}{totWP} \quad (4.5)$$

4.3. Filtrado colaborativo basado en confianza

En términos generales, los sistemas de recomendaciones se usan para estimar con la mayor precisión posible en qué grado un ítem específico puede ser del agrado de un usuario en particular. Específicamente, el filtrado colaborativo es un algoritmo de recomendación que basa sus predicciones en los ratings que han proporcionado otros usuarios en el sistema; en términos simples, bajo esta aproximación el sistema de recomendaciones busca usuarios cuyos ratings previos son similares a los del usuario objetivo para intentar predecir los ítems que probablemente son de su agrado [127]. Tradicionalmente los sistemas de recomendaciones basados en este tipo de filtro usan una métrica de similitud para encontrar *usuarios vecinos* y de acuerdo a las preferencias en ese conjunto de *vecinos* se calcula una predicción para un ítem específico. La ecuación 4.6 muestra la función de agregación con la que normalmente se calcula la predicción de un rating en el filtrado colaborativo.

$$P_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) \times W_{a,u}}{\sum_{u=1}^n W_{a,u}} \quad (4.6)$$

$P_{a,i}$ es el rating que predice el sistema de recomendaciones para un usuario a sobre el ítem i ; \bar{r}_a representa el promedio de los ratings de a , n corresponde al tamaño del vecindario (*neighborhood*) y $W_{a,u}$ es una métrica de similitud entre usuarios que frecuentemente se calcula a través de coeficientes de correlación como *Pearson* o *Spearman*. No obstante, en la práctica los sistemas de recomendaciones basados en el esquema colaborativo clásico presentan algunas debilidades relacionadas con la dispersión de los datos (típicamente los usuarios sólo califican una fracción de los ítems disponibles) o el problema de arranque en frío o *cold start* (los usuarios nuevos no han calificado los ítems necesarios para ser relacionados con otros usuarios); a esto se suma algo que es de mayor trascendencia para el dominio de la publicidad ubicua y que tiene que ver con la naturaleza misma del algoritmo para calcular similitud a partir de los ratings de usuarios anónimos.[110] y [111] demostraron que las personas tienden a creer más en recomendaciones de individuos en los cuales confían que en usuarios desconocidos. Esto supone una motivación importante para incorporar información de confianza entre usuarios a través del proceso de inferencia ilustrado en la sección anterior en el algoritmo de filtrado colaborativo.

Al respecto, trabajos previos han utilizado dos estrategias para incluir información de confianza en el algoritmo de recomendación: *promedio ponderado basado en confianza* y

4.3. Filtrado colaborativo basado en confianza

filtrado colaborativo basado en confianza. La primera técnica redefine la estrategia de recomendación al calcular un promedio ponderado basado en confianza; en lugar de calcular el rating promedio para un ítem i a partir del conjunto de ratings $r_{u,i}$ de todos los usuarios que ya están familiarizados con i , se incluye además valores $t_{a,u}$ que reflejan el grado de confianza para los raters u , de tal manera que los ratings de los usuarios más confiables tendrán un mayor peso (Ecuación 4.7).

$$p_{a,i} = \frac{\sum_{u \in n} t_{a,u} r_{u,i}}{\sum_{u \in n} t_{a,u}} \quad (4.7)$$

Siguiendo esta aproximación, [31] propone un algoritmo denominado *Tidal Trust*. De acuerdo los resultados de esta investigación, esta estrategia no ofrece un beneficio claro sobre la precisión que ofrece el algoritmo de filtrado colaborativo clásico, salvo en los casos de ratings controversiales, es decir existe una mejora en el proceso de recomendación para aquellos usuarios que difieren significativamente del rating promedio para un ítem específico.

Por otro lado, la segunda estrategia define un método alternativo para el cálculo del peso $W_{a,u}$ en la ecuación 4.6, al inferir el valor a partir de las relaciones del usuario objetivo en la red de confianza (usando técnicas de agregación o propagación). De esta manera, los pesos definidos en el Coeficiente de Correlación en la ecuación 4.6 son reemplazados por pesos de confianza $T_{a,u}$:

$$P_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) \times T_{a,u}}{\sum_{u=1}^n T_{a,u}} \quad (4.8)$$

Al respecto, [128] propone un ejemplo que sigue esta aproximación. De acuerdo a los hallazgos de este estudio, se obtuvo una mejora en la precisión de las recomendaciones para usuarios controversiales como en el caso anterior, pero adicionalmente se obtuvo un mejor comportamiento para usuarios nuevos (*cold start users*).

Al hacer un análisis de las dos aproximaciones, aunque ambas mejoran el comportamiento de las predicciones para ítems controversiales y pueden contribuir a disminuir el problema de *cold start* como en el segundo caso, el problema es que reemplazan el componente de correlación que calcula la similitud entre usuarios, probablemente asumiendo que la confianza y la similitud están relacionadas, de acuerdo a lo planteado en [129]. No obstante, para los propósitos de la presente investigación se considera que esta suposición no es exacta ya que la confianza entre usuarios no necesariamente es un indicador de *gustos similares*. En este sentido, se propone adaptar la técnica de filtrado colaborativo basada en confianza, reemplazando el componente de correlación de similitud de la ecuación con uno que incluya una contribución ponderada de similitud y confianza, como se ilustra en las ecuaciones 4.9 y 4.10.

$$P_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) \times WTS_{a,u}}{\sum_{u=1}^n WTS_{a,u}} \quad (4.9)$$

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

$$WTS_{a,u} = \alpha W_{a,u} + \beta T_{a,u} \quad (4.10)$$

En este caso, $\alpha + \beta = 1$, $T_{a,u}$ representa el score de confianza que se calcula a través del proceso descrito en la sección 4.2 y $W_{a,u}$ refleja la similitud entre usuarios calculada por el *Coeficiente de Correlación de Pearson* o alguno equivalente. Específicamente, el algoritmo calcula inicialmente el coeficiente de correlación entre usuarios y luego aplica el procedimiento para calcular el score de confianza entre los usuarios del vecindario (*neighborhood*) como se observa en la figura 4.5. Alternativamente, podría utilizarse una técnica donde precisamente los scores de confianza actúen como un filtro en el cual sólo los vecinos (*neighbors*) más confiables participen en el proceso de recomendación como se sugiere en [68]. No obstante, esta aproximación demanda un grupo de personas con un buen número de conexiones entre sí en la red social para asegurar una buena conformación del vecindario, lo cual resulta más complejo de implementar en la práctica. Por otro lado, α y β son pesos que permiten calibrar el comportamiento del algoritmo para dar una mayor contribución al factor similitud o al factor confianza durante el proceso de recomendación. Esta característica fue utilizada durante la experimentación para generar conclusiones alrededor de los resultados para diferentes combinaciones de similitud y confianza como se verá más adelante.

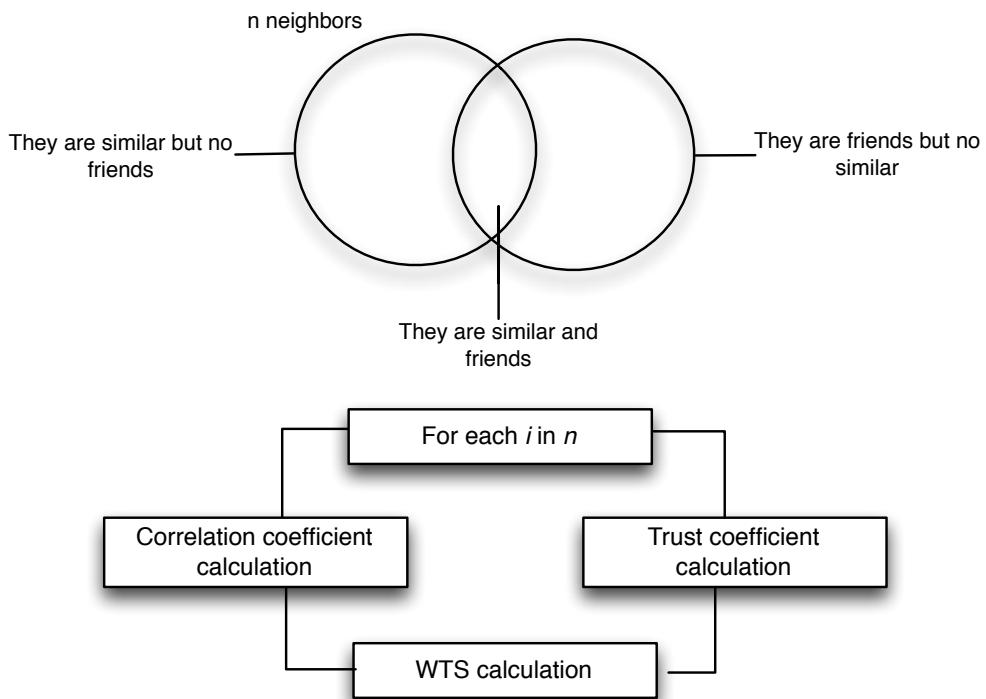


Figura 4.5: Inclusión de confianza en el algoritmo de recomendación. Fuente Propia.

4.4. Modelo de evaluación precisión/novedad

4.4. Modelo de evaluación precisión/novedad

Con frecuencia, la precisión ha sido la métrica por excelencia al momento de evaluar un sistema de recomendaciones. En términos simples, se define como la relación entre el número de items relevantes seleccionados (N_r) sobre el número de items seleccionados (N) o en otros términos, se refiere a la probabilidad de que un item seleccionado finalmente sea relevante para el usuario (ecuación 4.11).

$$P = \frac{N_r}{N} \quad (4.11)$$

Sin embargo, de acuerdo a las características que se analizaron anteriormente para el dominio de la publicidad ubicua, es más interesante evaluar el sistema de recomendaciones desde una perspectiva precisión/novedad. Aunque existen varias aproximaciones en la literatura para tratar de medir la novedad de las recomendaciones de un sistema de este tipo, [20] propone un framework interesante para la definición de métricas de diversidad y novedad que además unifica conceptos de diversos métodos propuestos en el estado del arte sobre este tópico. Específicamente, el modelo propone una aproximación de medida que tiene en cuenta el *ranking* (posición del item en la lista) y la *relevancia* de los items recomendados. Estas propiedades son de especial importancia para el dominio de estudio dada la naturaleza interactiva de la presente propuesta, puesto que éstas tienen en cuenta cómo los usuarios interactúan con las recomendaciones (los primeros items en la lista usualmente reciben más atención) y su subjetividad al momento de observarlas (qué tan relevante puede ser el item).

De acuerdo a los autores que proponen el modelo, la novedad de una pieza de información se refiere generalmente a "qué tan diferente es ésta con respecto a la información que se ha visto previamente" por parte de un usuario. No obstante, en el dominio de la publicidad ubicua la efectividad de los anuncios se mide no sólo por "qué tan diferentes son los anuncios con respecto a lo que se ha visto con anterioridad" sino también por "qué tan relevantes y de interés puedan resultar los anuncios para los usuarios". En este sentido, la métrica de novedad debería considerar los efectos de la posición de los items (*ranking*) y su relevancia durante el proceso de recomendación.

En términos concretos, el modelo se basa en tres relaciones fundamentales entre usuarios e items (figura 4.6): i) *descubrimiento*, un item es visto (o es familiar) por un usuario; ii) *elección*, un item es usado, seleccionado o consumido por un usuario; iii) *relevancia*, un item es útil, del interés o del agrado de un usuario. Estas tres variables se encuentran naturalmente relacionadas: un item que ha sido elegido, debe ser visto previamente y los items relevantes tienen mayor probabilidad de ser elegidos que los items irrelevantes; para simplificar el modelo, se asume que los items relevantes siempre son elegidos cuando ellos son vistos, los items irrelevantes nunca son elegidos y los items son descubiertos independientemente de su relevancia. En términos de una distribución probabilística, estas relaciones

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

se pueden expresar de acuerdo a la siguiente expresión 4.12:

$$p(\text{choose}) \sim p(\text{seen})p(\text{rel}) \quad (4.12)$$

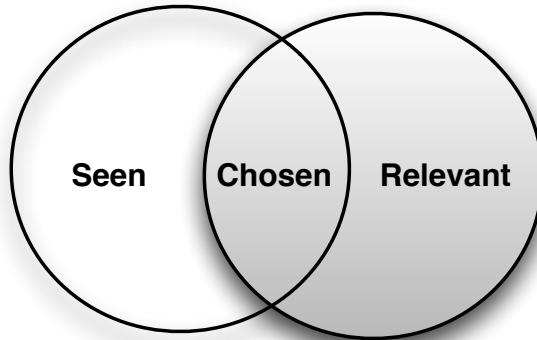


Figura 4.6: Principios básicos del modelo de novedad. [20].

Específicamente, dada una lista rankeada de items R que se ha recomendado a un usuario, la novedad se puede representar como:

$$m(R | \theta) = C \sum_{t=\in R} p(\text{choose} | i, u, R) nov(i, \theta) \quad (4.13)$$

Donde C es una constante de normalización y $p(\text{choose} | i, u, R)$ refleja el modelo de navegación sobre las recomendaciones sustentado en la elección de items, denotando la probabilidad de que el usuario objetivo u decida realmente usar el item i cuando se entrega una recomendación R ; este componente proporciona un mecanismo para manejar la sensibilidad de la métrica a la relevancia del item y su posicionamiento en la lista de recomendaciones. Por su parte, $nov(i, \theta)$ representa un modelo de novedad de item específico, que para los propósitos de la presente investigación, corresponde a una aproximación basada en la popularidad del item, en la cual se asigna los valores más altos a los items rezagados (aquellos con los que pocos usuarios han interactuado) y los valores más bajos corresponden a los top items (los más populares), por supuesto teniendo en cuenta los parámetros de ranking y relevancia. De acuerdo a las características del dominio, esta aproximación tiene sentido no solamente para los usuarios sino también para los promotores de la publicidad; frecuentemente, los dueños de las campañas buscan promover nuevos productos y probablemente estos anuncios serán considerados items rezagados por el sistema de recomendaciones en una etapa inicial. Por lo tanto, una métrica de cómo se desempeña el sistema en estos casos pueden resultar de utilidad para quienes promueven las campañas publicitarias. Igualmente, se espera que el comportamiento del sistema al respecto mejore con la inclusión de características multi-pantalla como lo sugiere una de las hipótesis del presente trabajo.

4.5. Recomendaciones dirigidas a grupos

De acuerdo con los planteamientos anteriores, bajo el modelo basado en popularidad la novedad puede ser definida como la diferencia entre un ítem y lo que "ha sido observado antes" en un contexto determinado. En términos matemáticos, este principio puede ser representado como la probabilidad de que un ítem no haya sido visto antes:

$$nov(i | \theta) = 1 - p(seen | i, \theta) \quad (4.14)$$

En esta expresión, θ es una variable de contexto genérica que considera diferentes perspectivas en la definición de novedad; específicamente, θ representa cualquier elemento del cual pueda depender el descubrimiento de los ítems, por ejemplo un usuario específico, un grupo de usuarios, intervalos de tiempo, etc.

En resumen, a continuación se describe el modelo matemático definido para sustentar la métrica de novedad de acuerdo a un modelo basado en popularidad, que se ajusta mejor a las características del dominio de la publicidad ubicua:

$$nov(R | u) = C \sum_{i_k \in R} disc(k)p(rel | i_k, u)(1 - p(seen | i_k)) \quad (4.15)$$

De acuerdo a la ecuación 4.15, la métrica de novedad puede leerse como el *número esperado de ítems recomendados relevantes que no fueron vistos previamente*. La expresión incluye un componente de *ranking* $disc(k)$ que define un decremento logarítmico de acuerdo a la posición del ítem en la lista:

$$disc(k) = \frac{1}{\log_2(k + 1)} \quad (4.16)$$

La ecuación 4.15 también incluye un componente de relevancia $p(rel | i_k, u)$, el cual puede ser modelado como un mapeo heurístico entre los valores de los ratings y la probabilidad de relevancia, de acuerdo a la siguiente función:

$$p(rel | i, u) \sim \frac{2^{g(u,i)} - 1}{2^{g_{max}}} \quad (4.17)$$

$$g(u, i) = \max(0, r(u, i) - \tau) \quad (4.18)$$

En estas expresiones, g es una función de utilidad derivada a partir de los ratings, donde τ representa el valor de indiferencia del rating (a partir del cual se hace relevante el ítem dependiendo de la escala utilizada) de acuerdo a los planteamientos de [130].

4.5. Recomendaciones dirigidas a grupos

Como parte del proceso de construcción del modelo de cooperación Smart TV - Smartphone para entornos de publicidad ubicua, específicamente para entornos de *Digital Signage*, se requiere un componente en el sistema de recomendaciones que entregue sugerencias de

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

anuncios dirigidas a un grupo de usuarios que observan la pantalla pública, como fue concebido en la descripción realizada en la sección 3.2 del capítulo 3. Para los propósitos de la presente investigación, se divide el sistema de recomendaciones en dos componentes diferenciados: uno *grupal* y otro *personal* (4.7); el primer componente, es el responsable de generar los anuncios que finalmente serán desplegados en la pantalla del Smart TV (display público) y el segundo, genera los anuncios que se desplegarán en la pantalla de los Smartphones de cada uno de los usuarios. Específicamente, este segundo componente utiliza el esquema colaborativo basado en confianza que fue descrito en la sección 4.3.

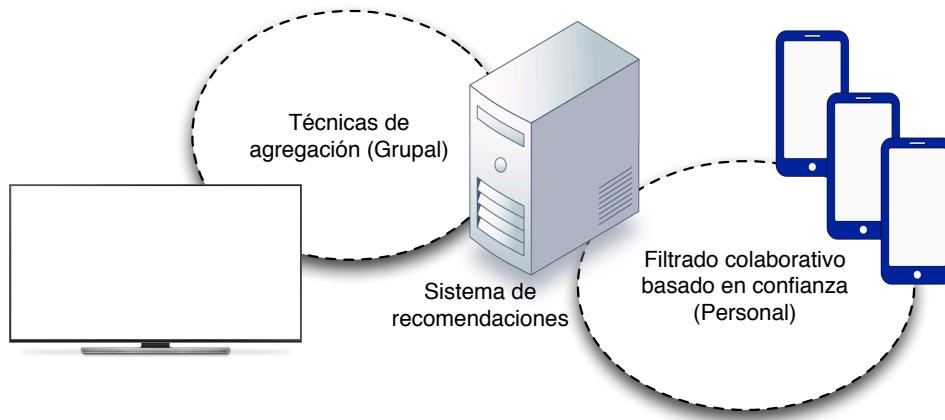


Figura 4.7: Componentes del sistema de recomendaciones. Fuente Propia.

En el caso del componente de recomendaciones grupal, se realizó un estudio de algunas aproximaciones que pudieran aplicarse en el dominio de la publicidad ubicua. En este caso, cabe resaltar que el propósito está dirigido a fortalecer la estrategia de despliegue de las recomendaciones a través de un esquema multi-pantalla, como se propone en el diseño del modelo de cooperación como uno de los principales aportes del presente trabajo, más que diseñar nuevos algoritmos de recomendaciones para perfiles grupales como lo han adelantado otras investigaciones.

Cuando se habla de sistemas de recomendaciones grupales, su función más obvia radica en la capacidad de *agregar* o *promediar* los modelos y/o predicciones de los individuos que conforman el grupo [131]. En este sentido,[77] sugiere un conjunto de fases que deberían ser abordadas por un sistema de recomendaciones de este tipo como se muestra en la tabla 4.4.

De acuerdo a las características del modelo de cooperación planteado, es claro que las fases 1 y 3 se ven claramente beneficiadas por la definición de un esquema multipantalla como se verá más adelante en el siguiente capítulo cuando se describa el piloto implementado durante la fase de experimentación. De otro lado, la fase 4 es un proceso que puede ser aplicable de manera opcional en un entorno de digital signage, pero no es el caso más

4.5. Recomendaciones dirigidas a grupos

Fase del proceso de recomendación	Diferencia con respecto a recomendaciones individuales
1. Los miembros especifican sus preferencias	Es deseable que los miembros examinen las especificaciones de las preferencias de los otros miembros
2. El sistema genera las recomendaciones	Se debe aplicar algún procedimiento para agregar las preferencias de los miembros
3. El sistema presenta las recomendaciones a los miembros del grupo	La conveniencia de una solución (posiblemente diferente) para los miembros individuales se convierte en un factor importante
4. Los miembros del equipo deciden sobre la recomendación (si aplica)	La decisión final no necesariamente recae en una persona. Se puede requerir un proceso de negociación

Tabla 4.4: Fases en el proceso de recomendación grupal. Fuente [77].

frecuente si se analizan los aspectos relacionados con la conformación del grupo: de acuerdo a lo planteado por [15], el grupo se puede formar intencionalmente cuando los miembros buscan un objetivo común o simplemente se puede producir de forma accidental; de otro lado, el tipo de presencia frente a la pantalla está determinado por la frecuencia con que las personas visitan el sitio donde ésta se encuentra ubicada, lo cual significa que existirán miembros persistentes pero también miembros ocasionales. Adicionalmente, el aspecto social de los grupos está determinado por el grado de afinidad que éstos puedan tener entre sí, esto es desde amigos hasta completamente desconocidos. Por naturaleza, en la mayoría de los casos en un escenario de digital signage, la conformación de los grupos se da de manera *ad-hoc*, es decir accidentalmente, al tiempo que persisten los usuarios ocasionales y desconocidos entre sí. Esto significa, que generalmente no se producirán discusiones con el ánimo de tomar decisiones frente al conjunto de recomendaciones que se despliegan en pantalla.

Por otra parte, en lo que respecta a la fase 2 propuesta por [77], diversas técnicas de agregación han sido propuestas en diferentes investigaciones como fue abordado anteriormente en el capítulo 2. Con el ánimo de dotar al esquema de cooperación multipantalla propuesto de un mecanismo de recomendación grupal, se estudiaron las técnicas de agregación propuestas por Masthoff [78], las cuales se han tomado como base en otras investigaciones. En síntesis, Masthoff propone un conjunto de 10 técnicas que tienen sus orígenes en las teorías de la elección social, las cuales han sido ampliamente exploradas desde hace varios años en campos como la economía, la política, la sociología y las matemáticas. La tabla 4.5 incluye una breve descripción de estas técnicas.

En lo que respecta al dominio de la publicidad ubicua y para los propósitos de la presente investigación, se considera que las técnicas relacionadas con esquemas de votación (*plurality voting, approval voting, copeland rule*) no son apropiadas dada su naturaleza explícita con respecto a la interacción por parte de los usuarios; otras técnicas como *Most respected person* no son viables de implementar en escenarios de digital signage, dada la naturaleza ad-hoc de la conformación de los grupos como fue señalado anteriormente. En este sentido, se decide estudiar más a fondo tres de las técnicas propuestas con fines de agregación para el modelo de cooperación propuesto: *Additive (Utilitarian), Least misery y Most Pleasure*; estas estrategias de agregación son fácilmente asimilables desde el punto de vista del sistema de recomendaciones y adicionalmente son coherentes con los principios exhibidos en

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

Estrategia de agregación	Descripción
Plurality voting	Cada miembro del grupo vota por su alternativa preferida. Se elige la alternativa con mayor número de votos.
Utilitarian	Se usan valores de utilidad para cada alternativa (con respecto a la satisfacción esperada), lo cual se consigue de dos maneras:
Additive	Se suman los ratings. Entre más grande sea el valor mejor posicionada aparecerá la alternativa en la secuencia.
Multiplicative	Se multiplican los ratings. Entre más grande sea el valor mejor posicionada aparecerá la alternativa en la secuencia.
Borda count	Se conceden puntos a cada alternativa de acuerdo a su posición en la lista de preferencias del usuario (la última obtendrá cero puntos, la penúltima un punto y así sucesivamente).
Copeland Rule	Corresponde a una aproximación de votos por mayoría. Ordena las alternativas de acuerdo al índice de Copeland: el # de veces que una alternativa se impone a otras menos el # de veces que ésta pierde con respecto a otras alternativas.
Approval voting	Se les permite votar a los miembros por el número de alternativas que deseen. Esta estrategia promueve la elección moderada de alternativas, al considerar aquellas que no son del todo interesantes para los miembros.
Least misery	Crea una nueva lista con el mínimo de los ratings individuales. Los items se seleccionan con respecto a los ratings en esta lista, el mejor calificado estará mejor posicionado.
Most pleasure	Crea una nueva lista con el máximo de los ratings individuales. Los items se seleccionan con respecto a los ratings en esta lista, el mejor calificado estará mejor posicionado.
Average without misery	Crea una nueva lista con el promedio de los ratings individuales, sin considerar items cuyo score se encuentre por debajo de un umbral específico para los miembros del grupo.
Fairness	Se seleccionan los items mejor calificados por parte de todos los miembros. Cuando existen items con igual calificación, se toma en cuenta las opiniones de otros individuos.
Most respected person	Se usan los ratings del miembro con mayor ascendencia en el grupo. Los ratings de otros miembros sólo se toman en cuenta para elegir entre items que exhiben una calificación similar.

Tabla 4.5: Técnicas de agregación para recomendaciones grupales. Fuente [78].

4.5. Recomendaciones dirigidas a grupos

el modelo de evaluación precisión/novedad propuesto, en el cual intervienen aspectos relacionados con *ranking* y *relevancia*. A continuación se describe con mayor detalle cada una de ellas, de acuerdo a lo presentado por Masthoff.

- **Additive:** En esta estrategia se suman los ratings, de tal manera que entre más grande sea el valor, mejor posicionado aparecerá el ítem en la secuencia. Cuando se usa en una forma ponderada donde los pesos están ligados a los ratings individuales, esta aproximación es similar a la que se usa en el filtrado colaborativo clásico. Esta técnica es usada en el sistema INTRIGUE [83], usando pesos que dependen del número de personas en el subgrupo y la relevancia del subgrupo. A manera de ejemplo, en la tabla 4.6 se muestra una matriz de ratings y la lista de recomendaciones que sería sugerida al grupo siguiendo esta aproximación.

	A	B	C	D	E	F	G	H	I	J
Jhon	10	4	3	6	10	9	6	8	10	8
Adam	1	9	8	9	7	9	6	9	3	8
Mary	10	5	2	7	9	8	5	6	7	6
Grupo	21	18	13	22	26	26	17	23	20	22
Lista de recomendaciones	(E, F) H (D, J) A I B G C									

Tabla 4.6: Técnica de agregación Additive. Fuente [78].

- **Least misery:** Crea una nueva lista con el mínimo de los ratings individuales. Los ítems se seleccionan con respecto a los ratings en esta lista, de tal manera que el mejor calificado estará mejor posicionado; la idea detrás de esta estrategia es que el grupo se encuentra tan satisfecho como el menos satisfecho de sus miembros. El sistema POLYLENS [80] utiliza esta estrategia, asumiendo que los grupos de personas que se reúnen para ver una película tienden a ser pequeños, lo cual favorece en algún grado la aplicación de esta técnica. A manera de ejemplo, en la tabla 4.7 se muestra una matriz de ratings y la lista de recomendaciones que sería sugerida al grupo siguiendo esta aproximación.

	A	B	C	D	E	F	G	H	I	J
Jhon	10	4	3	6	10	9	6	8	10	8
Adam	1	9	8	9	7	9	6	9	3	8
Mary	10	5	2	7	9	8	5	6	7	6
Grupo	1	4	2	6	7	8	5	6	3	6
Lista de recomendaciones	F, E, (H, J, D), G, B, I, C, A									

Tabla 4.7: Técnica de agregación Least Misery. Fuente [78].

- **Most Pleasure:** Crea una nueva lista con el máximo de los ratings individuales. Los ítems se seleccionan con respecto a los ratings en esta lista, de tal manera que el mejor calificado estará mejor posicionado. A manera de ejemplo, en la tabla 4.8 se

Capítulo 4. Sistema de recomendaciones basado en confianza para entornos de publicidad ubicua

muestra una matriz de ratings y la lista de recomendaciones que sería sugerida al grupo siguiendo esta aproximación.

	A	B	C	D	E	F	G	H	I	J
Jhon	10	4	3	6	10	9	6	8	10	8
Adam	1	9	8	9	7	9	6	9	3	8
Mary	10	5	2	7	9	8	5	6	7	6
Grupo	10	9	8	9	10	9	6	9	10	8
Lista de recomendaciones	(A, E, I), (B, D, F, H), (C, J), G									

Tabla 4.8: Técnica de agregación Most Pleasure. Fuente [78].

Capítulo 5

Prototipo y Experimentación

Este capítulo describe el conjunto de pruebas que se realizaron para evaluar diferentes aspectos del sistema de recomendaciones para entornos de publicidad ubicua basado en un esquema de cooperación Smart TV - Smartphone. En términos generales, el entorno de pruebas se desarrolla alrededor de un piloto en el dominio de Digital Signage que permite hacer una evaluación de manera integral tanto a nivel del sistema de recomendaciones (teniendo en cuenta aspectos de precisión/novedad) como a nivel del middleware Smart TV - Smartphone que soporta el modelo de cooperación construido. Con este objeto, se llevan a cabo pruebas en entornos simulados (*offline*) y con usuarios reales (*online*). Específicamente, se diseña un modelo experimental basado en el trabajo de [132], con el ánimo de comprobar las hipótesis planteadas en el capítulo 3 y que se retoman a continuación:

H1: *la inclusión de un esquema de cooperación multi-pantalla mejora el balance precisión/novedad durante el proceso de recomendación.*

H2: *la inclusión de información de confianza en el algoritmo de filtrado colaborativo mejora el balance precisión/novedad durante el proceso de recomendación.*

De acuerdo a este esquema, inicialmente se realiza una descripción del piloto, posteriormente se analizan algunas consideraciones relacionadas con el dominio de aplicación y los datasets utilizados durante las pruebas y finalmente se presentan los resultados de los experimentos *offline* y *online* para el sistema.

5.1. Descripción del piloto

A manera de resumen, a continuación se sintetizan los aspectos más relevantes que hacen parte de la motivación para la construcción del piloto: aunque la mayoría de las aproximaciones para publicidad ubicua han sido dirigidas a dispositivos móviles (Smartphones o tablets), los espacios públicos son ampliamente atractivos para esta industria teniendo en cuenta que el 75 % de las decisiones de compra se toma en el establecimiento comercial o cerca de ellos [11]. En este sentido, se decide implementar un piloto en un escenario de

Digital signage para evaluar el comportamiento del sistema de recomendaciones involucrando aspectos de similitud y confianza, soportado además en un esquema de cooperación Smart TV - Smartphone. Este tipo de ambientes, sugiere el análisis de tres importantes requerimientos: i) entrega de anuncios personalizados y adaptados al contexto; ii) entrega de anuncios a *individuos y grupos de individuos*; iii) la precisión de las recomendaciones es una métrica que se emplea frecuentemente para evaluar los sistemas de recomendaciones, pero el grado de novedad puede ser aún más importante en el dominio publicitario con fines de persuasión.

Con respecto al primer requerimiento, el contexto social del usuario es una de las variables de mayor relevancia en el dominio publicitario. Por años, el *word of mouth* ha sido una de las herramientas publicitarias más utilizadas, luego la inclusión de información relacionada con el contexto social del usuario en el algoritmo de recomendación (específicamente la confianza en otros usuarios), puede convertirse en un mecanismo para obtener la influencia de otros individuos que hacen parte del círculo social cercano del usuario durante el proceso de recomendación; el efecto de esta aproximación puede ser importante con fines de persuasión, si se tiene en cuenta que el 67 % de las decisiones de compra son influenciadas por las opiniones de usuarios cercanos. Con respecto al segundo y tercer requerimiento, las recomendaciones dirigidas a grupos de individuos implica una serie de desafíos que han sido abordados por otros trabajos, los cuales han sido tomados como referencia para la presente investigación. No obstante, la introducción de una mejora en el proceso de recomendación en estos casos, no sólo depende del algoritmo de recomendación en sí, sino también de una mejor estrategia de despliegue. La mayoría de iniciativas relacionadas con pantallas públicas interactivas no consideran aproximaciones multi-pantalla donde el contenido pueda distribuirse de forma complementaria, haciendo partícipes también a los displays de los dispositivos personales de los usuarios. Por ende, este tipo de estrategia también puede contribuir positivamente en la percepción de novedad: por definición, las recomendaciones dirigidas a grupos que se despliegan en una pantalla pública serán menos personalizadas que las que se despliegan en un dispositivo personal, luego podrían resultar más novedosas para los usuarios.

A partir de los planteamientos anteriores, se construye una alternativa novedosa a las carteleras de anuncios tradicionales que suelen encontrarse en los cafés internet o en los campus universitarios, en las cuales los usuarios publican y acceden al contenido de ofertas escritas en hojas de papel que se encuentran adheridas sobre la superficie. En su lugar, el viejo tablero es reemplazado por una cartelera electrónica *interactiva* soportada en el modelo de cooperación Smart TV - Smartphone propuesto. A través de este esquema, los usuarios no sólo tienen la posibilidad de interactuar con el contenido de la pantalla pública (*Smart TV*) a través de sus Smartphones, sino que también los anuncios son desplegados en las pantallas de ambos dispositivos bajo aproximaciones distintas pero complementarias: recomendaciones de anuncios para el perfil grupal en la pantalla del Smart TV y recomendaciones personalizadas que incorporan información de confianza inferida desde la red social en las pantallas de los dispositivos móviles (Figura 5.1).

5.1. Descripción del piloto

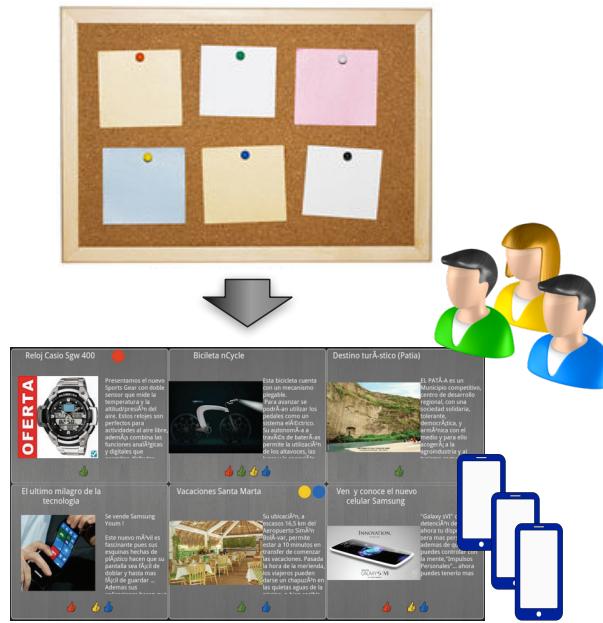


Figura 5.1: Cartelera electrónica de anuncios. Fuente Propia.

En lo que respecta a la implementación del piloto, se desarrollaron aplicaciones sobre la plataforma Android tanto para los Smartphones como para el set top box, éste último soportado en la plataforma de Google TV. Ambas aplicaciones usan las funcionalidades del middleware a través del API correspondiente, como fue descrito en el capítulo 3. En cuanto al ingreso al sistema, los usuarios usan una funcionalidad *Login with Facebook*, lo cual permite identificar a cada uno de ellos para realizar el proceso de inferencia de confianza a partir de la información disponible en la red social, como será descrito más adelante.

La figura 5.2 muestra la arquitectura desplegada durante la realización del experimento. A continuación, se resumen algunas de las funcionalidades más importantes del piloto:

- **Recomendaciones de anuncios para un grupo de usuarios que observa la pantalla:** el sistema de recomendaciones usa técnicas de agregación (como las descritas en el capítulo 4) para calcular la mejor lista de anuncios para un grupo de personas que interactúa con la pantalla principal y las organiza en listas de 6 items. La elección de estos números obedece a razones de usabilidad, dado el tamaño del TV que se utilizó durante las pruebas (42 pulgadas) (Figura 5.3).
- **Recomendaciones personalizadas de anuncios que se despliegan en las pantallas de los Smartphones:** el sistema de recomendaciones calcula la mejor lista de anuncios para cada una de las personas que se encuentra frente al Smart TV, usando los algoritmos descritos en el capítulo 4, y finalmente se despliegan en las pantallas de sus dispositivos móviles (Figura 5.4). El usuario tiene la capacidad de obtener información más detallada sobre un anuncio específico y agregarlo a su lista de favoritos

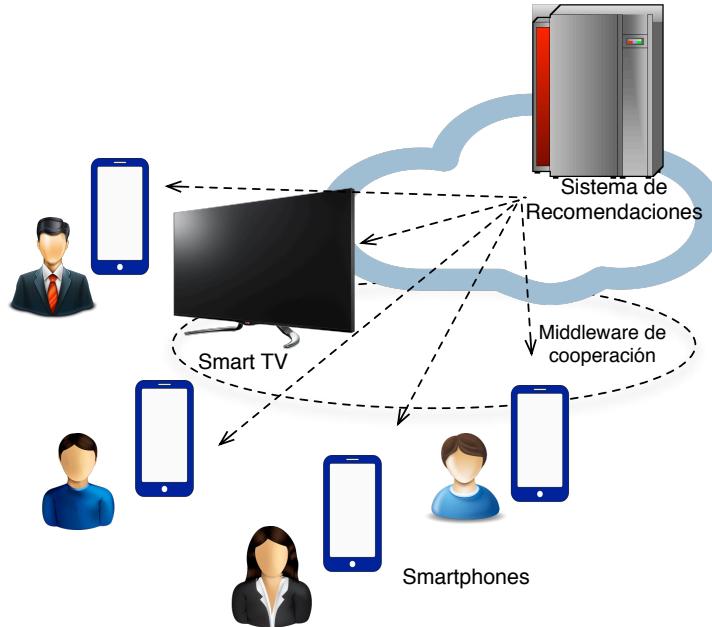


Figura 5.2: Arquitectura del piloto. Fuente Propia.



Figura 5.3: Recomendaciones de anuncios para un perfil grupal. Fuente Propia.

5.1. Descripción del piloto

cuando así lo deseé.



Figura 5.4: Recomendaciones de anuncios para un perfil individual. Fuente Propia.

- **Interacción básica entre los Smartphones y la pantalla pública:** cada usuario puede navegar a través de los anuncios desplegados en la pantalla principal a través de un control tipo pad desde la pantalla del Smartphone; la interacción es diferenciada a través de un color distintivo para cada uno. Adicionalmente, a través de un gesto de toque sobre el pad (*tap gesture*) el usuario puede visualizar información detallada en su Smartphone sobre un anuncio que se ha seleccionado en la pantalla pública. (Figura 5.3 y 5.5).
- **Calificación de anuncios:** cada usuario puede calificar los anuncios exhibidos en la pantalla pública o en la pantalla de su Smartphone a través de las opciones *Me gusta* o *No me gusta* disponibles en la interfaz de la aplicación móvil. En el caso de la pantalla principal, cada usuario es identificado a través de un color específico (Figura 5.3).
- **Exhibición de anuncios:** cada usuario puede crear sus propios anuncios desde la aplicación de su Smartphone incluyendo un texto y una foto cargada desde la galería o directamente desde la cámara, para luego exhibirlos en la pantalla pública (Figura 5.5).
- **Logs de interacción:** usando las capacidades del middleware, ambas aplicaciones (Smart TV, Smartphone) tienen la capacidad de guardar información con respecto a la actividad del usuario durante el proceso de interacción. Para el caso del piloto, estas



Figura 5.5: Control tipo pad con fines interactivos y posteо de anuncios. Fuente Propia.

capacidades son de especial relevancia para generar calificaciones (*ratings*) implícitas hacia el sistema de recomendaciones de acuerdo a la acción realizada (solicitar más información sobre un anuncio, ignorar anuncios en la pantalla, agregar un anuncio a favoritos, etc.) como se verá más adelante.

5.2. Consideraciones del dominio

Una vez realizada la descripción del piloto implementado, es importante resaltar algunas consideraciones acerca del dominio de aplicación que fueron tenidas en cuenta durante la fase de experimentación.

- (i) En primer lugar, el sistema de recomendaciones debe estar enfocado en la tarea de encontrar *algunos buenos items*, no *todos los buenos items* son requeridos en el escenario propuesto.
- (ii) La maximización de la utilidad para el usuario, no sólo está relacionada con la precisión de las recomendaciones, sino también con el grado de novedad de las mismas. De hecho esta característica puede ser aún más importante que la primera en el dominio de la publicidad ubicua con fines de persuasión.
- (iii) Aunque la tasa de falsos positivos se puede considerar de alguna manera como publicidad *spam*, algunos de estos anuncios pueden resultar novedosos, así que es deseable mantener un balance entre falsos positivos y anuncios que exhiban novedad.

5.3. Consideraciones sobre los datasets

- (iv) Finalmente, la tasa de falsos negativos es particularmente relevante para los *advertisers* si se tiene en cuenta que es coherente con sus intereses la recomendación de items que ellos consideran relevantes.

5.3. Consideraciones sobre los datasets

Teniendo en cuenta que el sistema de recomendaciones construido emplea un algoritmo de inferencia basado en confianza, se requieren dos tipos de datasets: un dataset con anuncios y ratings y otro que incluya *scores de confianza*. Precisamente, uno de los principales desafíos durante la fase de experimentación fue la ausencia de un dataset adecuado para el dominio publicitario, por lo cual se decide construir uno. En este sentido, en una primera fase se desarrolla una aplicación Web que permite la generación de anuncios y su respectiva calificación por parte de usuarios voluntarios de la Universidad del Cauca; en una segunda fase, los usuarios participan en sesiones interactivas usando el prototipo descrito en la sección 5.1 con el objeto de mejorar la información del dataset. Al final, se obtuvo un dataset con 127 anuncios, 176 usuarios y 10.128 ratings para la realización de las pruebas correspondientes.

Con respecto al dataset que incluye información de confianza, el principal reto era encontrar un grupo lo suficientemente homogéneo en el cual cada miembro del grupo tuviera al menos una conexión en Facebook con otro individuo. En este sentido, se decide generar esta información de forma aleatoria usando el dataset de ratings durante los tests *offline*, puesto que el propósito principal de este set de pruebas es observar el efecto de la inclusión de confianza durante el proceso de recomendación; las pruebas de *ground truth* para evaluar la precisión del algoritmo de inferencia, se realizaron previamente de acuerdo a lo descrito en la sección 4.2. Al final de este proceso se obtiene un dataset con 30.852 conexiones de confianza como se muestra en la figura 5.6. El grafo resultante muestra las conexiones entre usuarios, de tal manera que cada par de individuos conectados comparte un valor de confianza entre -1 y 1. En el mismo sentido, las conexiones verdes representan valores más altos de confianza, mientras que las rojas representan los valores más bajos; así mismo, en lo que respecta a los usuarios en el grafo, el color y el tamaño está determinado por el grado del nodo, siendo los nodos de color verde los de mayor rango, mientras que los de color rojo corresponden a los de menor rango.

Por otro lado, el desafío para los tests *online* es mucho más demandante si se tienen en cuenta los requerimientos de conexión entre usuarios de los que se habló anteriormente. En este orden de ideas, varios grupos de voluntarios fueron analizados para garantizar que cumplieran con las características requeridas durante el experimento. Al final del proceso, un grupo de cerca de veinte personas de la Fundación Innovagen de la ciudad de Popayán cumplieron con los requisitos de conexión en la red social y accedieron voluntariamente a participar durante las sesiones interactivas en el marco del proceso de experimentación. Durante las sesiones, se utilizó el API *Graph Explorer* de Facebook para extractar la información desde la red social con la respectiva autorización de cada uno de los usuarios.

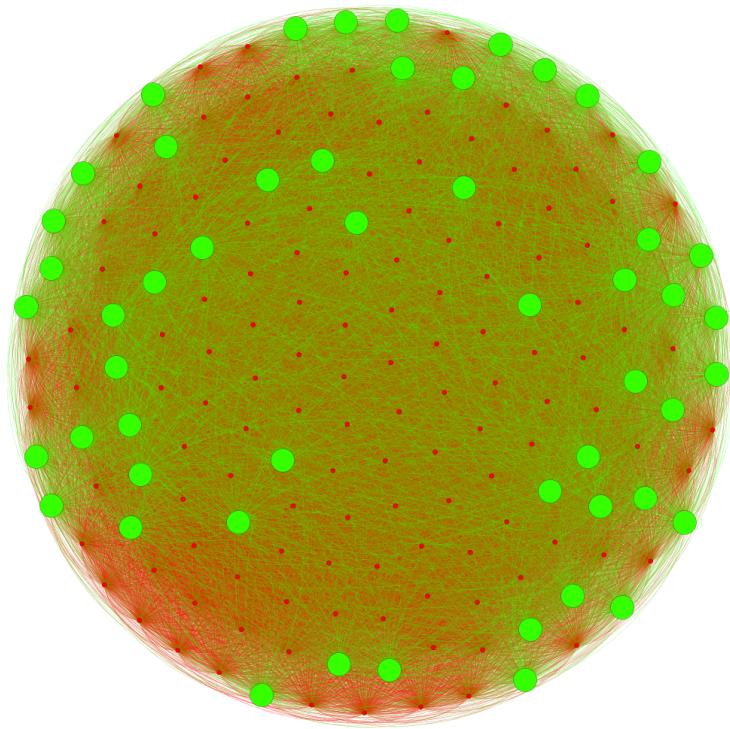


Figura 5.6: Grafo de confianza para el grupo de prueba. Fuente Propia.

Todos los datos fueron anonimizados durante el proceso, de tal manera que cada individuo fue identificado por una cadena numérica específica (ID) y sólo fue procesado el número de interacciones sin intervención sobre el contenido de los mensajes. Finalmente, una vez condensada la información correspondiente a las interacciones, se calcula el score de confianza entre usuarios de acuerdo al proceso descrito en la sección 4.2.

La figura 5.7 muestra el grafo que representa a las comunidades dentro del grupo. De acuerdo a lo observado, se detectaron 3 comunidades: en color verde la de mayor tamaño que a su vez alberga los nodos de mayor rango, y en color amarillo y rojo las comunidades con los nodos de menor rango. Esta información permite configurar con mayor claridad los grupos que hacen parte de la sesión interactiva usando el prototipo descrito en la sección 5.1. Debido a los altos rangos de los nodos observados en la comunidad en color verde, algunos de sus miembros participaron más de una vez durante el experimento.

5.4. Pruebas offline

Esta sección aborda los resultados de las pruebas *offline* en dos bloques diferenciados con respecto al sistema de recomendaciones y al middleware de cooperación Smart TV - Smartphone. En lo correspondiente al sistema de recomendaciones, las pruebas fueron

5.4. Pruebas offline

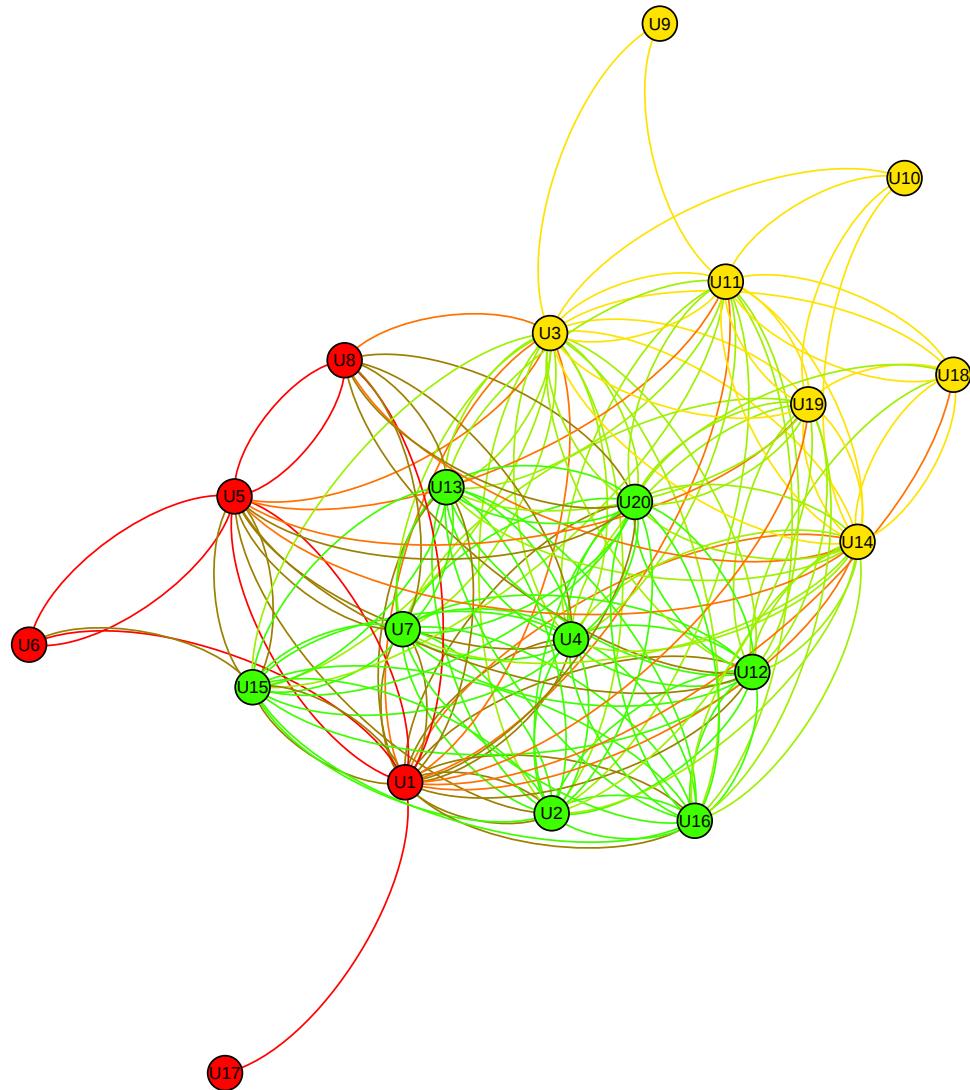


Figura 5.7: Grafo de interacción social en Facebook Fundación Innovagen. Fuente Propia.

realizadas utilizando el dataset contruido incluyendo ratings y scores de confianza con el propósito de evaluar la hipótesis $H2$ en cuanto a aspectos de precisión/novedad.

En lo que respecta a la plataforma que soporta el modelo de cooperación Smart TV - Smartphone, frecuentemente este tipo de middlewares orientados a mensajes (MOM) son evaluados considerando aspectos relacionados con el rendimiento del sistema. En este sentido, en lo posible los tests deberían ser realizados en entornos prácticos (con usuarios reales) pero también en condiciones extremas que generalmente se pueden simular [133], [134]. Específicamente en esta sección se abordarán los resultados de este segundo set de pruebas.

5.4.1. Pruebas del sistema de recomendaciones

Como se dijo anteriormente, las pruebas *offline* para el sistema de recomendaciones utilizan un dataset propio que incluye ratings y scores de confianza, como fue descrito en la sección 5.3. Tomando como referente lo planteado en la hipótesis $H2$, se realizaron diferentes pruebas para valores distintos de contribución de los componentes de similitud y confianza en la ecuación 4.10, con el ánimo de observar el efecto sobre la precisión y la novedad de las recomendaciones. Como se observa en la tabla 5.1, los diferentes pesos que se asignan a los componentes de similitud y confianza van desde un algoritmo de filtrado colaborativo clásico ($\alpha = 1, \beta = 0$) hasta un algoritmo de filtrado colaborativo basado totalmente en confianza ($\alpha = 0, \beta = 1$).

Test No.	Confianza (%)	Similitud (%)
1	100	0
2	90	10
3	80	20
4	70	30
5	60	40
6	50	50
7	40	60
8	30	70
9	20	80
10	10	90
11	0	100

Tabla 5.1: Contribución de los componentes de similitud y confianza para los diferentes tests. Fuente propia.

La figura 5.8 muestra los resultados de la precisión para los diferentes tests. Es interesante observar el pobre rendimiento del algoritmo de recomendación cuando se tiene una aproximación basada totalmente en confianza; este resultado es coherente con los hallazgos de investigaciones previas [31],[68]. Por consiguiente, se debería incrementar el valor de la

5.4. Pruebas offline

contribución del componente de similitud con el ánimo de mejorar la precisión cuando un score de confianza influye en el proceso de recomendación, como se evidencia en el gráfico.

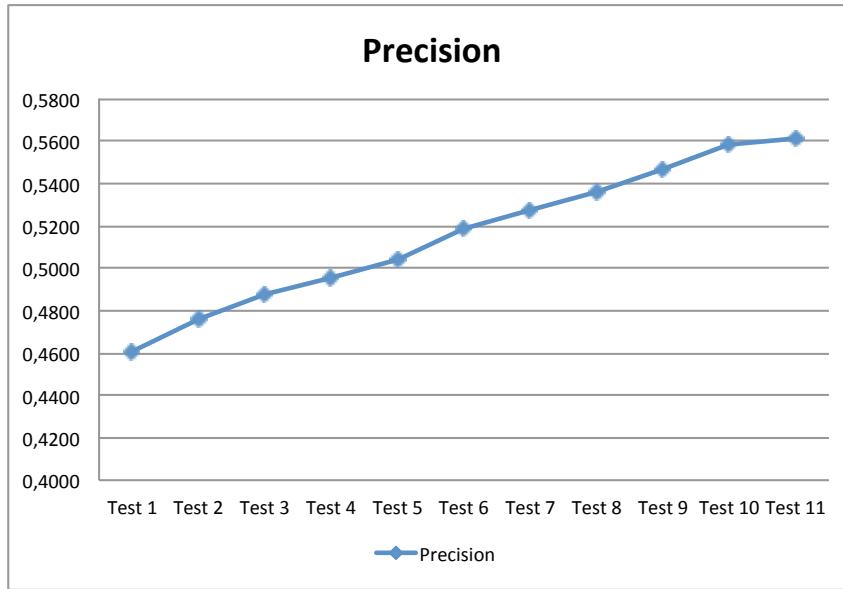


Figura 5.8: Resultados de precisión del sistema de recomendaciones para diferentes contribuciones confianza-similitud. Fuente Propia.

De acuerdo a estos resultados, es probable que el componente de confianza no tenga una influencia significativa sobre la precisión del algoritmo de recomendación si se compara con una aproximación de filtrado colaborativo clásico. No obstante, es pertinente realizar una análisis más profundo desde la perspectiva de la novedad de las recomendaciones. Para este efecto, se seleccionaron aleatoriamente 50 usuarios del dataset y se calculó el valor de novedad incluyendo factores de *ranking* y *relevancia*, de acuerdo al modelo descrito en la sección 4.4. Tomando como referencia los resultados anteriores para la precisión, se diseñan dos pruebas específicas: la primera para un filtro colaborativo clásico ($\alpha = 1, \beta = 0$) y la segunda para un filtro colaborativo basado en confianza con pesos de contribución equitativos para sus componentes de similitud y confianza ($\alpha = 0,5; \beta = 0,5$). La tabla 5.2 resume los resultados obtenidos.

Test	Media	N	Desviación estándar
Filtrado colaborativo clásico	0.18	50	0.058
Filtrado colaborativo basado en confianza	0.23	50	0.070

Tabla 5.2: Resultados de novedad para el sistema de recomendaciones incluyendo el componente de confianza. Fuente propia.

El valor de la media obtenida, sugiere que el filtrado colaborativo basado en confianza

exhibe un mejor comportamiento que el filtrado colaborativo clásico desde el punto de vista de la novedad de las recomendaciones. Se condujo un test T a través del cual se obtuvo un valor p de 0, lo cual evidencia que la diferencia es estadísticamente significativa, soportando lo planteado en la hipótesis $H2$. Así, los hallazgos de estas dos pruebas permiten concluir que en general la inclusión de confianza en el algoritmo de recomendación mejora el balance *precisión/novedad*. No obstante, es importante contrastar los resultados con los que se obtienen a partir de la participación de usuarios reales, como será descrito en la sección 5.5.1 durante las pruebas *online*.

5.4.2. Pruebas del middleware Smart TV - Smartphone

Durante esta fase de pruebas, se simularon componentes para generar condiciones de alto tráfico hacia el middleware, de acuerdo a la arquitectura de pruebas que se muestra en la figura 5.9. Como se puede observar, distintos dispositivos hardware enviaron y recibieron mensajes usando diferentes tasas de transmisión con una carga computacional diferente. Adicionalmente, la tabla 5.3 resume las características del hardware utilizado. A a continuación se presenta el análisis de los resultados obtenidos durante las pruebas.

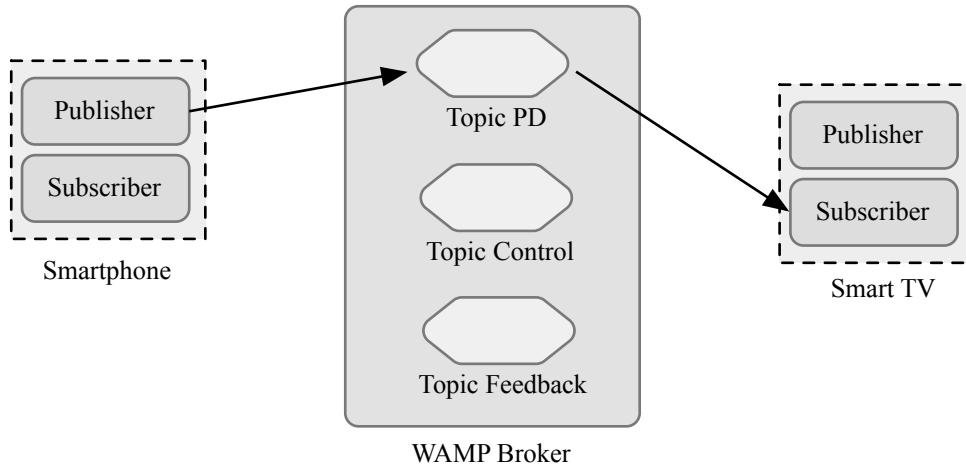


Figura 5.9: Arquitectura de pruebas para el middleware - tests offline. Fuente Propia.

Hardware	Smartphone	Smart TV	WAMP Broker
Tipo	Teléfono	Google TV	Laptop
CPU	Qualcomm Snapdragon 400 1.2 GHz	Intel Atom CE4150 1.2 GHz	Intel Core i5 2.5 GHz
RAM	1 GB	8 GB	8 GB
OS	Android 4.4	Android 3.2	Mac OS
Red	WiFi 802.11 g	WiFi 802.11 g	Ethernet

Tabla 5.3: Pruebas offline middleware - características HW

5.4. Pruebas offline

5.4.3. Definición del MST (Maximum Sustainable Throughput)

El propósito de esta prueba es determinar el máximo throughput sostenible por el middleware (MST). En este orden de ideas, se configura un Publisher y un Subscriber, de tal manera que el Publisher envía mensajes de 64 bytes de longitud a tasas variables. De esta manera, se mide la tasa de recepción de mensajes en el Subscriber a medida a medida que varía la relación de mensajes en el Publisher usando incrementos de 100 mps.

Como se puede observar en la figura 5.10, cuando se superan los 1500 mps en el Publisher, la tasa de recepción de mensajes en el Subscriber comienza a disminuir, lo cual permite concluir que el punto de saturación (MST) para el middleware es de 1500 mps para la configuración hardware utilizada.

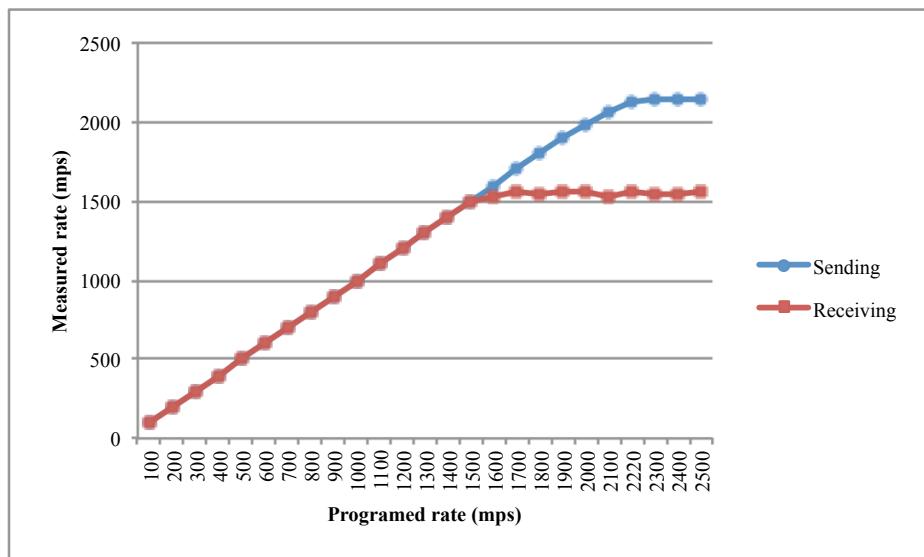


Figura 5.10: Comparación de las tasas de envío y recepción de mensajes. Fuente Propia.

5.4.4. Tasa efectiva de intercambio con MST

El propósito de esta prueba es observar el comportamiento de la tasa de recepción en el Subscriber en el tiempo cuando se mantiene la tasa de envío constante en el Publisher al valor del MST (1500 mps).

Como se puede observar en la figura 5.11, los resultados confirman la estabilidad del sistema en el tiempo sin alcanzar puntos de saturación aún manteniendo la tasa de envío al valor del MST.

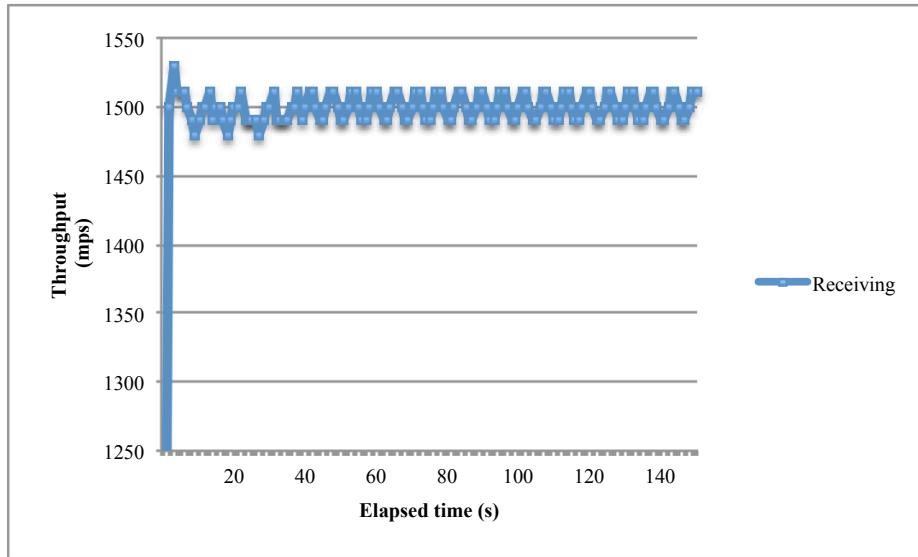


Figura 5.11: Tasa de recepción del subscriber con MST. Fuente Propia.

5.4.5. Consumo de CPU con MST

El propósito de esta prueba es observar el consumo de CPU en los principales nodos del sistema (Smart TV, Smartphone y Broker) en diferentes puntos en el tiempo manteniendo la tasa de envío en el valor del MST (1500 mps).

Como se puede observar en la figura 5.12, el consumo más alto de recursos de procesamiento se da en los primeros 5 segundos debido al establecimiento de los hilos de conexión. No obstante, el comportamiento se estabiliza a partir de los 10 segundos. Finalmente, se nota que el Smart TV exhibe los valores de consumo de CPU más elevados debido a que utiliza un procesador menos potente que el resto de los componentes.

5.4.6. Variación del MST con varios Publishers

El propósito de esta prueba es observar el comportamiento del MST cuando se incrementa el número de Publishers. En este sentido, se mantiene un único Subscriber usando mensajes de longitud fija de 64 bytes.

Como se puede observar en la figura 5.13, el MST desciende a medida que el número de Publishers se incrementa llegando a los 780 mps cuando 300 Publishers envían mensajes a una tasa de 10 mps. No obstante, estos resultados corresponden a circunstancias extremas que en la práctica no afectarían significativamente el rendimiento del middleware para entornos de digital signage.

5.4. Pruebas offline

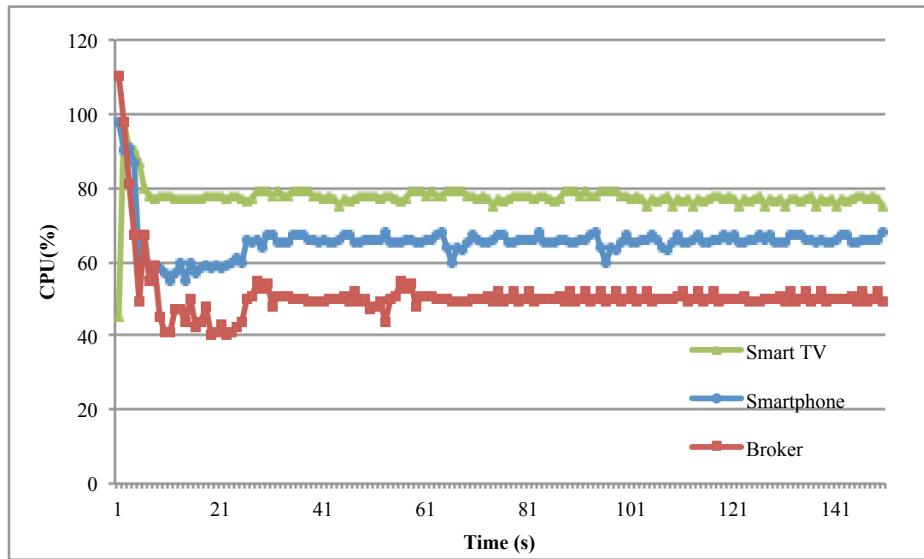


Figura 5.12: Consumo de CPU con MST. Fuente Propia.

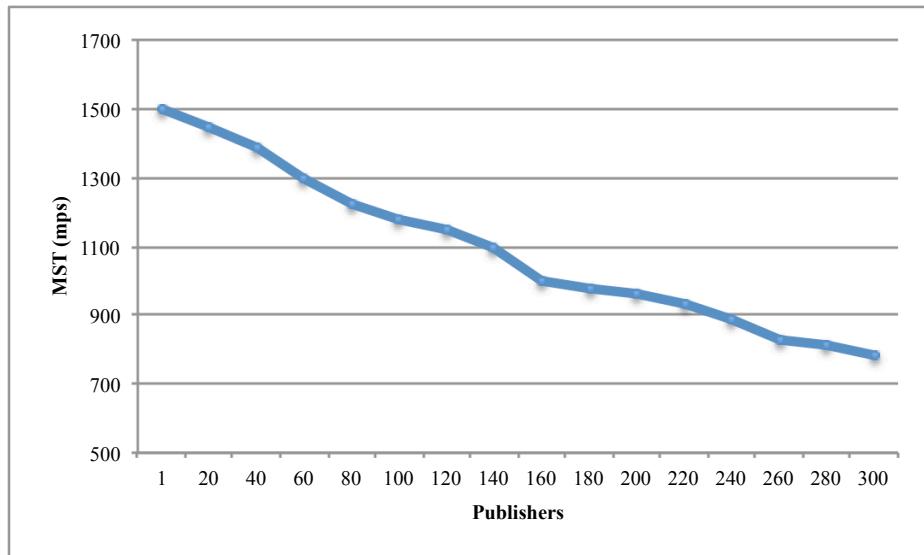


Figura 5.13: Variación del MST con varios Publishers. Fuente Propia.

5.4.7. Variación del MST con varios Subscribers

El propósito de esta prueba es observar el comportamiento del MST cuando se incrementa el número de Subscribers. En este sentido, se mantiene un único Publisher usando mensajes de longitud fija de 64 bytes.

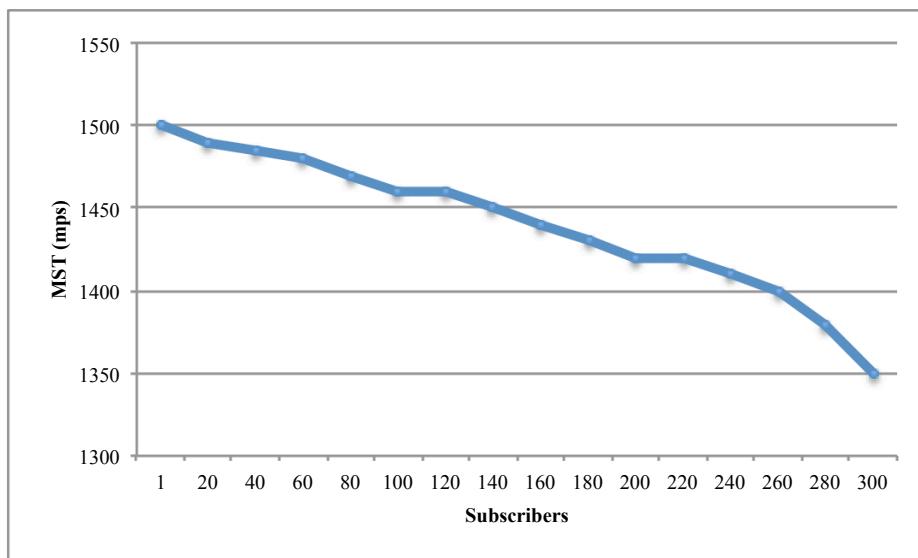


Figura 5.14: Variación del MST con varios Subscribers. Fuente Propia.

Como se puede observar en la figura 5.14, el MST desciende a medida que el número de Subscribers se incrementa llegando a los 1350 mps cuando se tienen 300 Subscribers. No obstante, a diferencia del caso anterior el impacto es significativamente menor ya que la mayor parte de la carga de procesamiento tiene lugar en el WAMP Broker.

5.4.8. Variación del MST con mensajes de diferente longitud

El propósito de esta prueba es observar el comportamiento del MST cuando se varía la longitud de los mensajes. Así, se mantiene un único Publisher y un único Subscriber mientras se varía la longitud de los mensajes incrementalmente.

Como se puede observar en la figura 5.15, el MST desciende a medida que la longitud de los mensajes se incrementa llegando a los 720 mps cuando el mensaje alcanza los 16.384 bytes (16 Kb), ya que se requiere mayor ancho de banda y recursos computacionales para procesar mensajes de mayor tamaño. Sin embargo, el valor máximo observado supera sustancialmente el tamaño de los mensajes que usualmente se intercambian en un escenario de Digital Signage interactivo como el que se describe en el piloto.

5.4. Pruebas offline

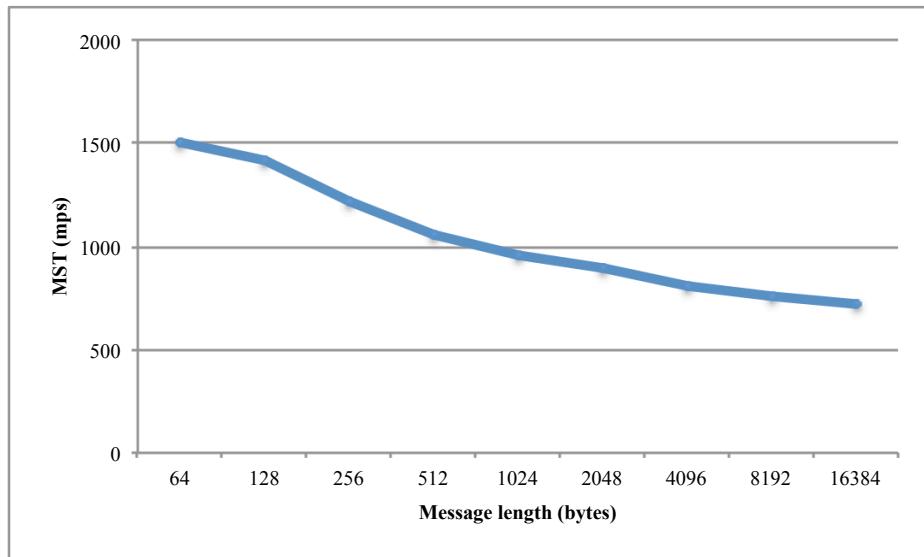


Figura 5.15: Variación del MST con mensajes de diferente longitud. Fuente Propia.

5.4.9. Tiempo de conexión y latencia

El propósito de esta prueba es observar el comportamiento de los tiempos de conexión y la latencia del sistema. Específicamente, el tiempo de conexión se define como el tiempo transcurrido entre la solicitud de apertura de la conexión WebSocket desde un cliente hasta la llegada de la respuesta por parte del WAMP Broker. Por otro lado, la latencia se refiere al tiempo transcurrido entre la publicación de un mensaje por parte del Publisher hasta la recepción del mensaje en el Subscriber. Para la realización de la prueba se usó un Publisher, un Subscriber y mensajes de 64 bytes de longitud. La tabla 5.4 resume los resultados obtenidos sobre un total de 1000 muestras.

	Promedio	Desviación estándar
Tiempo de conexión	26.56 ms	7.61
Latencia	40.24 ms	9.15

Tabla 5.4: Tiempos de conexión y latencia media.

De acuerdo a los resultados obtenidos, los tiempos de conexión y la latencia del sistema son altamente satisfactorios para los propósitos de un middleware interactivo para entornos de digital signage, lo cual se traduce en una mejora de la experiencia del usuario como se observará más adelante.

5.5. Pruebas online

Durante la realización de las pruebas online se utilizó la infraestructura del piloto implementado descrito en la sección 5.1. Al igual que en la sección anterior, este apartado aborda los resultados de las pruebas *online* en dos bloques diferenciados con respecto al sistema de recomendaciones y al middleware de cooperación Smart TV - Smartphone. En lo que respecta al sistema de recomendaciones, las pruebas se diseñaron de acuerdo a los planteamientos realizados en las hipótesis *H1* y *H2* para comprobar los efectos tanto de la introducción de un esquema multi-pantalla en el despliegue de las recomendaciones, como en la puesta en operación del componente de confianza sobre el algoritmo de filtrado colaborativo. En lo que respecta al middleware de cooperación Smart TV - Smartphone, en la sección anterior las pruebas offline se enfocaron en la evaluación general de diferentes parámetros relacionados con el rendimiento del sistema bajo condiciones extremas. Por su parte, las pruebas online fueron realizadas en un ambiente real de digital signage usando el piloto descrito en la sección 5.1.

Específicamente, durante el experimento grupos de 3 usuarios se ubicaron en frente de la pantalla e interactuaron desde sus Smartphones con los anuncios de la cartelera electrónica en periodos de 5 a 10 minutos, al tiempo que el sistema capturó logs con la información de cada sesión para su posterior procesamiento; el número de individuos se restringe a este número principalmente por dos razones: en primer lugar, por las características de sus conexiones en la red social y en segundo lugar, la búsqueda de una mejor experiencia para el usuario dado el tamaño de la pantalla principal (42 pulgadas).

5.5.1. Pruebas del sistema de recomendaciones

Como se dijo anteriormente, el propósito de estos tests está relacionado con la comprobación de los planteamientos de las hipótesis *H1* y *H2*. En ese orden de ideas, de acuerdo a lo expuesto en la sección 5.3, uno de los grandes desafíos de esta prueba estuvo relacionado con la conformación de un grupo homogéneo con suficientes conexiones entre sí que permitiera una correcta inferencia de confianza a partir de la información disponible en la red social. Un grupo de veinte (20) voluntarios de la Fundación Innovagen reunieron estos requisitos para realizar los tests en dos sesiones: durante la primera, el sistema de recomendaciones usó una aproximación de filtrado colaborativo clásico ($\alpha = 1; \beta = 0$) para entregar anuncios en los dispositivos personales de los usuarios (Smartphones), mientras que durante la segunda sesión el sistema de recomendaciones incluyó componentes de similitud y confianza usando pesos equitativos ($\alpha = 0,5; \beta = 0,5$) de acuerdo a los resultados obtenidos en las *pruebas offline*.

Se conformaron un total de 8 grupos de 3 integrantes cada uno para participar en el experimento de acuerdo a la información entregada por el grafo de conexiones disponible en la red social; en consecuencia, algunos de ellos participaron en al menos dos grupos debido a la estructura de sus conexiones en la red social. Con respecto a las recomendaciones grupales desplegadas en el Smart TV, se alternaron las técnicas de agregación *Least Misery*

5.5. Pruebas online

y *Most Pleasure* entre los grupos para evaluar el comportamiento de cada una de ellas. En una primera versión del piloto, aún sin incluir el algoritmo de inferencia en el sistema de recomendaciones, se realizaron experimentos previos que avalaron la elección de estas dos técnicas para una segunda fase de la experimentación. En este primer piloto, un grupo de 49 estudiantes del programa de Turismo de la Universidad del Cauca con edades entre los 20 y los 24 años, participaron en una experiencia interactiva a través de una primera versión del modelo de cooperación Smart TV - Smartphone propuesto usando un dataset con 137 anuncios y 2190 ratings. En este sentido, las técnicas de agregación *Additiva*, *Least Misery* y *Most Pleasure* fueron sometidas a evaluación.

A través de una encuesta, se indagó sobre el nivel de novedad percibido por parte de los participantes para cada set de recomendaciones entregado por cada una de las técnicas. Las tablas 5.5 y 5.6 muestran un resumen de los resultados obtenidos.

Técnica de agregación	Tamaño muestra	Media	Dev. estandar
Additive	16	3.438	1.209
Least misery	18	3.944	0.802
Most pleasure	14	3.214	0.699

Tabla 5.5: Nivel de novedad percibido técnicas de agregación

Test	Hipótesis nula	Hipótesis alternativa	p
1	$u_{LM} = u_A$	$u_{LM} > u_A$	0.084
2	$u_{LM} = u_{MP}$	$u_{LM} > u_{MP}$	0.005

Tabla 5.6: Nivel de novedad percibido prueba de hipótesis para las técnicas de agregación

Como se puede observar, el análisis partió del planteamiento de una hipótesis nula en la cual se asume que la novedad percibida a través del uso de la técnica *Additiva* es la misma con respecto a la de *Least Misery* y una segunda hipótesis en el mismo sentido que involucra las técnicas de *Least Misery* y *Most Pleasure*. En ambos casos se considera una hipótesis alternativa, la cual propone que la estrategia de *Least Misery* ofrece un mayor grado de novedad percibida. De acuerdo a los resultados, aunque no fue posible concluir si existe una diferencia contundentemente significativa sobre la estrategia aditiva, se observa un mejor comportamiento de la estrategia de *Least Misery* sobre la estrategia de *Most Pleasure*. Para complementar el análisis, se realizó un estudio similar considerando esta vez la satisfacción percibida por parte de los usuarios.

Los resultados en las tablas 5.7 y 5.8 muestran una inclinación favorable nuevamente hacia la técnica de *Least Misery* y un menor rendimiento de la técnica aditiva. Luego, se evidencia un mejor balance novedad/precisión a través del uso de las técnicas de *Least Misery* y *Most Pleasure*, por lo cual son elegidas para la segunda fase de la experimentación usando la infraestructura del piloto descrito en la sección 5.1.

De acuerdo a lo anterior, durante el experimento se usó la técnica *Least Misery* con los

Técnica de agregación	Tamaño muestra	Media	Dev. estándar
Additive	16	3.375	0.957
Least misery	18	4.056	0.725
Most pleasure	14	3.5	0.941

Tabla 5.7: Nivel de satisfacción percibido técnicas de agregación

Test	Hipótesis nula	Hipótesis alternativa	p
1	$uLM = uA$	$uLM > uA$	0.014
2	$uLM = uMP$	$uLM > uMP$	0.040

Tabla 5.8: Nivel de satisfacción percibido prueba de hipótesis para las técnicas de agregación

grupos impares (1, 3, 5 y 7) y la técnica *Most Pleasure* con los grupos pares (2, 4, 6 y 8). La tabla 5.9 resume las diferentes variantes de los algoritmos usados durante las pruebas.

Grupo	Smart TV	Smartphone
	Técnica agregación	Algoritmo RS
Par	Least Misery (LM)	$S1 \alpha = 1, \beta = 0$ $S2 \alpha = 0.5, \beta = 0.5$
Impar	Most Pleasure (MP)	$S1 \alpha = 1, \beta = 0$ $S2 \alpha = 0.5, \beta = 0.5$

Tabla 5.9: Configuración de las sesiones para los tests online

Durante cada sesión, los usuarios interactuaron con el sistema por espacios de 5 a 10 minutos. Durante la interacción, los participantes realizaron diferentes acciones como navegar sobre los anuncios (en la pantalla del Smart TV y el Smartphone), calificar anuncios (en la pantalla del Smart TV y el Smartphone), detallar un anuncio desplegado en la pantalla pública en la pantalla del Smartphone, o adicionar anuncios a la categoría de Favoritos. Específicamente, la tarea de calificación explícita de anuncios usó una escala binaria (del tipo *like*, *dislike*), ya que ésta cobra más sentido para el usuario en un contexto de *digital signage* que una escala clásica de 1 a 5. No obstante, el modelo de cooperación Smart TV - Smartphone propuesto, introduce un mecanismo novedoso para capturar ratings implícitos para el sistema a través de un mapeo entre las acciones realizadas por el usuario y una escala clásica de 1 a 5 que es la que usa finalmente el sistema de recomendaciones; esta característica, es un soporte importante a las exigencias de un entorno de publicidad ubicua. La tabla 5.10 muestra el mapeo de escalas utilizado.

Adicionalmente, al final de cada sesión se capturó la percepción de los usuarios a través de una encuesta corta que se muestra en la tabla 5.11, la cual permite completar el análisis desde una perspectiva cualitativa.

Finalmente, se usaron las capacidades del middleware Smart TV - Smartphone para capturar logs sobre las actividades de interacción de los usuarios en formato JSON para posteriormente realizar el procesamiento de datos respectivo. A continuación, se resumen

5.5. Pruebas online

Acción del usuario	Escala RS
Like explícito	5
Agregar a favoritos	4
Detallar anuncio	3
Ignorar un anuncio en la pantalla	2
Dislike explícito	1

Tabla 5.10: Mapeo entre las acciones del usuario y la escala del sistema de recomendaciones

Sesión No.

1. En qué pantalla percibiste recomendaciones más ajustadas a tus preferencias personales?

Televisor
 Teléfono/Tablet

2. En qué pantalla percibiste recomendaciones más novedosas (que no conocías, pero que podrían ser de tu interés)?

Televisor
 Teléfono/Tablet

Tabla 5.11: Encuesta para capturar la percepción de los usuarios durante la sesión interactiva

los hallazgos más importantes de la experimentación.

5.5.2. Influencia de la confianza sobre la precisión de las recomendaciones

La figura 5.16 muestra la diferencia (*gap*) entre los valores de precisión durante las dos sesiones del experimento para cada grupo ($[\alpha = 1, \beta = 0] - [\alpha = 0,5, \beta = 0,5]$). Como se puede observar, los resultados son coherentes con la tendencia observada durante los tests offline: la diferencia es siempre positiva, lo cual significa que un peso más alto para el componente de similitud (α) incrementará el valor de la precisión; la variación observada para la precisión de las recomendaciones estuvo entre 0.03 y 0.09 (*valor p = 0.0*).

De acuerdo a estos resultados, se espera un efecto positivo sobre la novedad de las recomendaciones, el cual será analizado en la siguiente sección.

5.5.3. Influencia de la confianza sobre la novedad de las recomendaciones

La tabla 5.12 muestra un análisis estadístico descriptivo con respecto al efecto sobre la novedad al introducir el componente de confianza en el algoritmo de recomendación. En este caso, la métrica de novedad incluyó los factores de ranking y relevancia y fue calculada durante cada sesión para realizar el análisis comparativo. Como se puede observar, la novedad se afecta positivamente cuando el componente de confianza se incluye en el algoritmo de recomendación lo cual es coherente con los resultados observados durante los tests of-

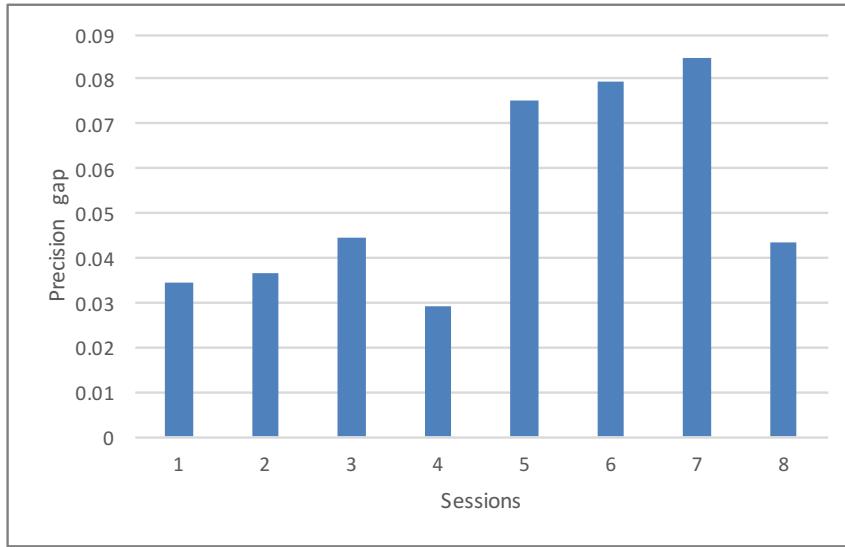


Figura 5.16: Diferencia en los valores de precisión entre las sesiones de prueba. Fuente Propia.

line. En consecuencia, existe una buena evidencia para soportar los planteamientos de la hipótesis $H2$.

Sesión	Mean	Std. dev.	Std. error mean
S1. $\alpha = 1, \beta = 0$	0.624678330	0.081433326	0.019194019
S2. $\alpha = 0,5, \beta = 0,5$	0.707231408	0.079869995	0.018825538
<i>valor p</i>			0.011

Tabla 5.12: Influencia de la confianza sobre la novedad en las recomendaciones

5.5.4. Influencia del esquema multi-pantalla sobre la novedad de las recomendaciones

La tabla 5.13 muestra un análisis estadístico descriptivo con respecto al efecto que causa la implementación de un esquema multi-pantalla sobre la novedad de las recomendaciones. En este caso, se calculó el valor de la novedad para las recomendaciones grupales desplegadas en el Smart TV y las recomendaciones personalizadas mostradas en los Smartphones incluyendo el componente de confianza en el algoritmo ($\alpha = 0,5, \beta = 0,5$). Al igual que en el caso anterior, la métrica de novedad consideró los factores de ranking y relevancia.

Como se puede observar, el valor de novedad es mayor para las recomendaciones entregadas en el Smart TV para el perfil grupal, lo cual se constituye en una buena evidencia para soportar los planteamientos de la hipótesis $H1$. No obstante, se realizó un análisis más profundo teniendo en cuenta la inclusión del componente de confianza y la percepción de los participantes durante el experimento. La figura 5.17, muestra los resultados para el número de casos en los cuales el valor de novedad de las recomendaciones grupales supera el

5.5. Pruebas online

Estrategia recomendación	Mean	Std. dev.	Max.	Min.
Filtrado colaborativo basado en confianza (Smartphone)	0.392169169	0.149873432	0.245628642	0.798169602
Técnica de agregación (Smart TV)	0.456121580	0.118898340	0.299660378	0.683989866
			Valor p	0.02

Tabla 5.13: Influencia del esquema multi-pantalla sobre la novedad en las recomendaciones

valor de novedad de las recomendaciones individuales, incluyendo y excluyendo el componente de confianza del algoritmo de recomendación. En este caso, igualmente se observaron diferentes variantes de la métrica de novedad, básicamente incluyendo y excluyendo los factores de ranking y relevancia. En este sentido, la tendencia observada es coherente con los resultados anteriores, dado que el valor de novedad para las recomendaciones grupales es mayor en más del 50 % de los casos, independientemente de la inclusión del componente de confianza en el algoritmo de recomendación. Sin embargo, existe un hallazgo interesante: cuando se incluye el componente de confianza, el número de casos donde el valor de novedad de las recomendaciones grupales es más alto disminuye.

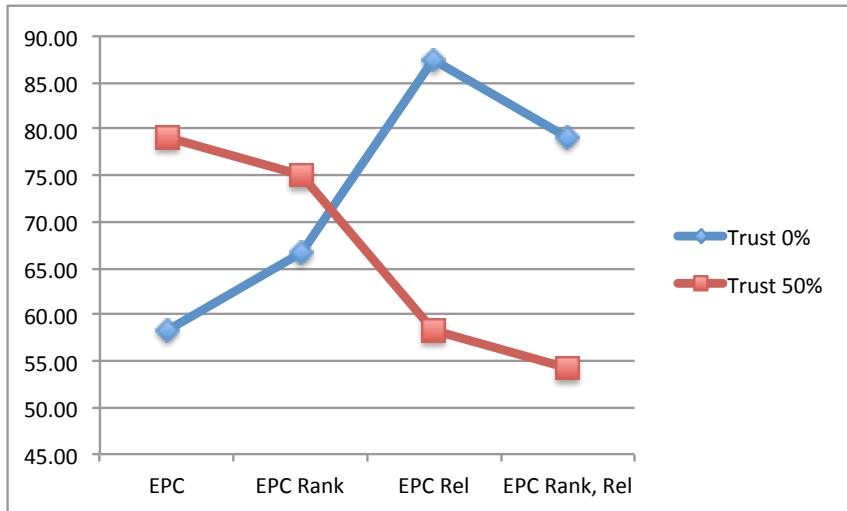


Figura 5.17: Número de casos donde la novedad de las recomendaciones grupales es mayor. Fuente Propia.

La justificación para este comportamiento puede analizarse a partir de los resultados sobre la percepción de los usuarios que se observa en la figura 5.18. De acuerdo a los valores entregados por la encuesta, es interesante observar cómo la inclusión del componente de confianza en el algoritmo de recomendación mejora la percepción de novedad para las recomendaciones personalizadas que se entregan en los Smartphones, lo cual no sólo es coherente con los hallazgos descritos en las secciones 5.4.1 y 5.5.3, sino que también explíca el comportamiento observado.

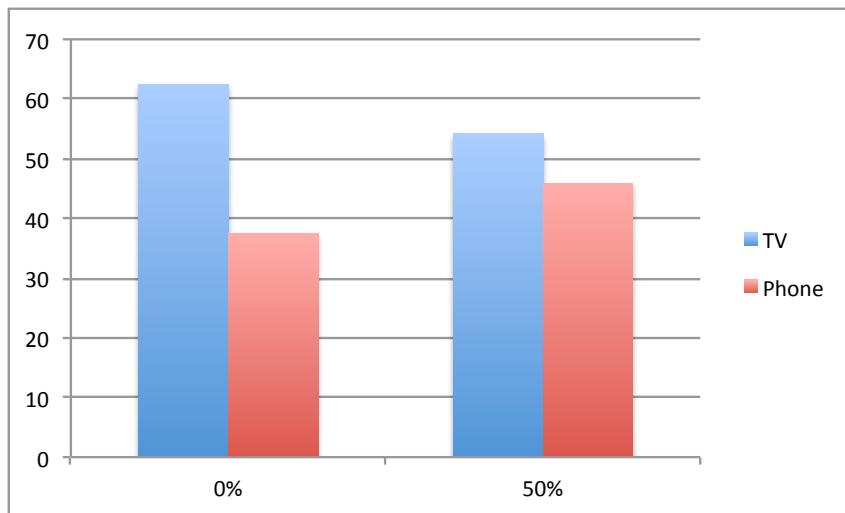


Figura 5.18: Percepción de novedad de los usuarios cuando se incluye el componente de confianza.
Fuente Propia.

En conclusión, aunque el componente de confianza tiene un efecto positivo sobre la novedad de las recomendaciones personalizadas que se entregan en los Smartphones, el uso de una aproximación multi-pantalla favorece igualmente la percepción de novedad con respecto a las recomendaciones grupales. Estas evidencias, soportan los planteamientos de las hipótesis $H1$ y $H2$.

5.5.5. Influencia de la técnica de agregación sobre la novedad de las recomendaciones

Inicialmente, se analizaron los resultados de la encuesta para comparar los resultados de la percepción de los usuarios con respecto a los resultados del análisis cuantitativo. La figura 5.19 muestra la tendencia con respecto a la novedad percibida por parte de los participantes usando una técnica de agregación específica durante ambas sesiones. Como se puede observar, los resultados son coherentes con los hallazgos descritos en la sección anterior para el efecto de la implementación del esquema multi-pantalla sobre la novedad de las recomendaciones para las dos técnicas de agregación consideradas (LM y MP). No obstante, la técnica de MP parece exhibir un mejor comportamiento que la técnica de LM , específicamente durante la segunda sesión (*confianza 50 %*), pero no hubo evidencia estadística suficientemente significativa ($p = 0.558$), por lo cual se procede a realizar un análisis cuantitativo más profundo.

La tabla 5.14 muestra un análisis estadístico descriptivo sobre el efecto de la técnica de agregación utilizada sobre la novedad de las recomendaciones grupales. En este caso, la métrica de novedad incluyó los factores de ranking y relevancia y fue calculada para las diferentes sesiones del experimento.

De acuerdo a los resultados obtenidos, existe evidencia que la técnica de agregación

5.5. Pruebas online

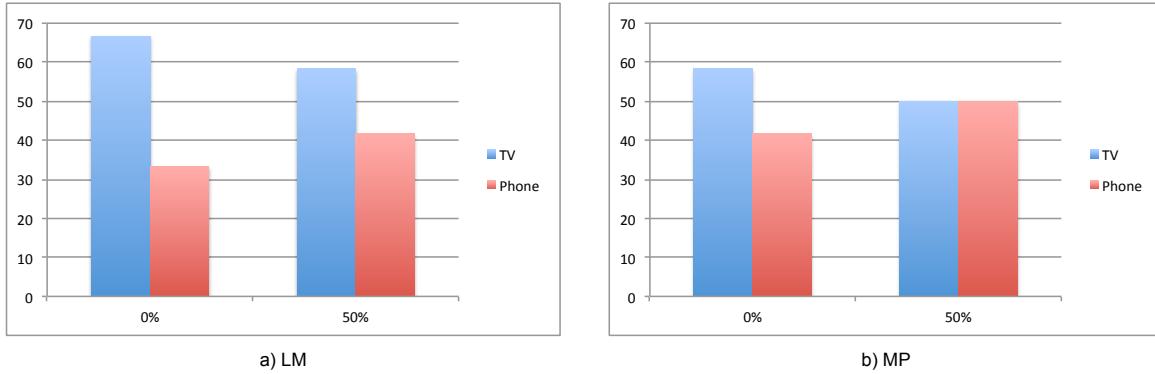


Figura 5.19: Percepción de novedad de los usuarios por técnica de agregación. Fuente Propia.

Técnica agrupación	Mean	Std. dev.	Std. error mean
LM	0.404645536	0.113326506	0.032714544
MP	0.507597625	0.104568416	0.030186302
<i>Valor p</i>			0.03

Tabla 5.14: Influencia de la técnica de agregación sobre la novedad en las recomendaciones

utilizada afecta el valor de novedad para las recomendaciones grupales con un valor ligeramente más positivo para la técnica de *MP*. Por otro lado, la figura 5.20 muestra la tendencia observada cuando se comparan las dos técnicas de agregación teniendo en cuenta el número de casos donde el valor de la novedad de las recomendaciones grupales supera al valor de novedad de las recomendaciones personalizadas. Como se esperaba, la técnica de *MP* exhibe un mejor comportamiento de que la técnica de *LM*, incluyendo los factores de ranking y relevancia en la métrica, pero el efecto es menos evidente cuando se habilita el componente de confianza en el algoritmo de recomendación, dado que éste incrementa el valor de novedad para las recomendaciones personalizadas de acuerdo a los hallazgos descritos en la sección 5.5.4.

5.5.6. Pruebas del middleware Smart TV - Smartphone

En términos generales, se observa una clara fluidez y estabilidad del sistema durante la experiencia de interacción de los usuarios. En este sentido, se decide realizar un seguimiento sobre el consumo de CPU y RAM en cada componente durante un periodo de 5 minutos, para validar cuantitativamente el comportamiento observado. Las figuras 5.21 y 5.22 muestran un bajo consumo de recursos y un comportamiento estable en líneas generales, lo cual es coherente con el comportamiento observado durante la prueba. Es interesante observar los cuatro picos iniciales (prueba realizada con cuatro usuarios simultáneos), los cuales tienen lugar cuando cada uno de los usuarios realiza una solicitud de conexión y un nuevo conjunto de recomendaciones debe ser entregado, lo cual es coherente igualmente con los

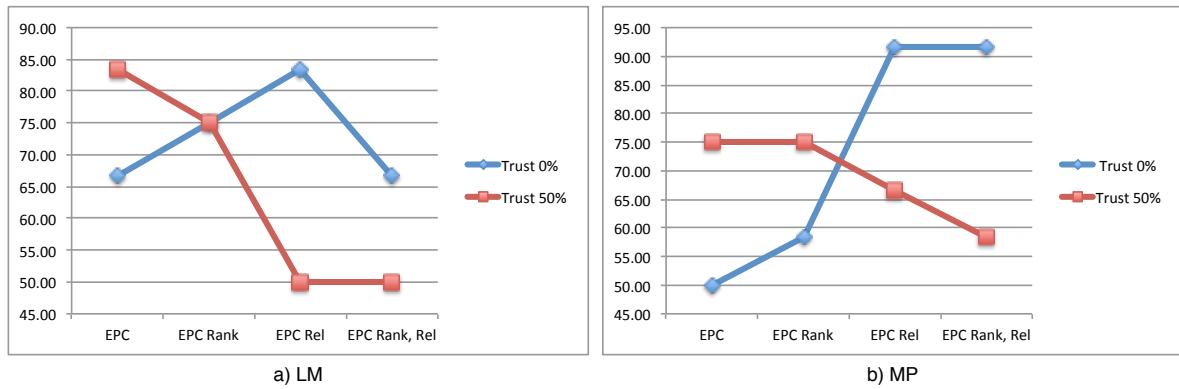


Figura 5.20: Novedad por técnica de agregación (Valor novedad recomendaciones grupales > Valor novedad recomendaciones individuales). Fuente Propia.

resultados observados en las pruebas offline.

En resumen, el comportamiento observado del sistema durante la experiencia con usuarios reales y los parámetros de rendimiento reflejados durante las pruebas offline sugieren un buen funcionamiento del middleware para la mayoría de entornos de Digital Signage en la práctica.

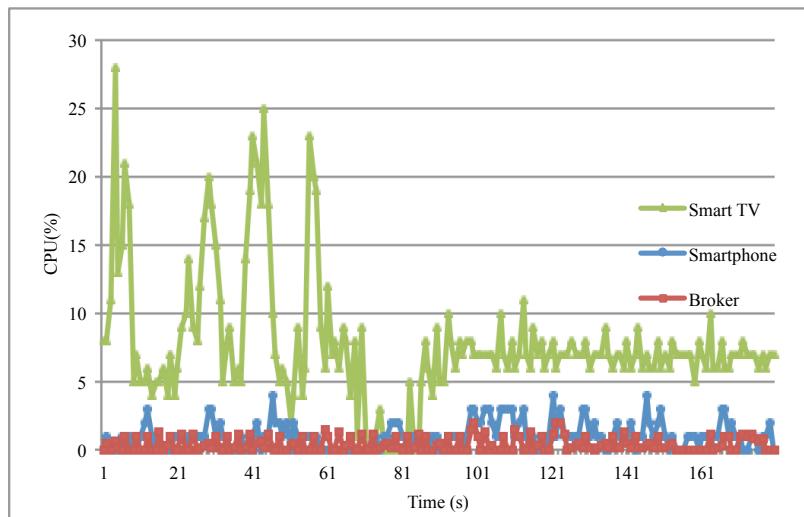


Figura 5.21: Consumo de CPU - Prueba online. Fuente Propia.

5.5. Pruebas online

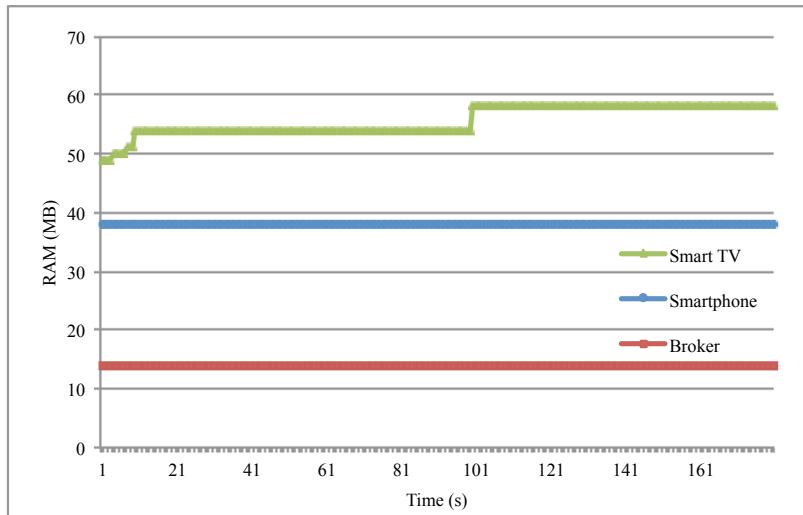


Figura 5.22: Consumo de RAM - Prueba online. Fuente Propia.

Capítulo 6

Conclusiones y trabajos futuros

6.1. Aportes del trabajo de investigación

La presente tesis doctoral desarrolló una aproximación para construir un sistema de recomendaciones basado en un esquema de cooperación Smart TV - Smartphone para entornos de publicidad ubicua. Aunque las teorías que rigen los sistemas de recomendaciones han sido estudiadas desde hace más de dos décadas, el diseño de un sistema de este tipo parte del análisis del dominio de aplicación, lo cual conlleva al estudio de aspectos particulares de cada entorno que hacen único cada proceso de construcción, como lo plantea [43]. En este orden de ideas, el análisis del dominio de la publicidad ubicua tomó como referencia la resolución de tres retos principales:

i) *la personalización y la adaptación al contexto*: el desarrollo de un sistema de recomendaciones contribuye a la mejora de la aproximación *broadcast* que usualmente manejan los sistemas de publicidad en entornos de digital signage, en los cuales se exhibe el mismo set de anuncios para todas las personas que se acerca a la pantalla pública. En este sentido, se eligió una aproximación colaborativa *User x User* para generar las recomendaciones; no obstante, otro aspecto que surge a partir del análisis del dominio motivó el desarrollo de una mejora en el filtrado colaborativo clásico: la inclusión de información contextual basada en datos de la red social del usuario, de alguna manera, una forma simple de incluir la técnica de *word of mouth* ampliamente utilizada en la publicidad tradicional. Para ello, se desarrolló un algoritmo de filtrado colaborativo que incluye un *score* de confianza que se calcula a partir de la información disponible en la red social Facebook, más específicamente a partir de las interacciones de las personas en la red, dado que investigaciones previas demostraron que este es el mecanismo más efectivo al momento de inferir la confianza entre individuos. A partir de esta reflexión, se estudiaron diversos antecedentes para seleccionar un conjunto inicial de variables que sirviera como punto de partida al momento de construir el algoritmo de inferencia de confianza. Estas variables fueron procesadas de forma ponderada a través de la técnica estadística PCA (Principal Component Analysis), luego de un proceso de normalización que tiene en cuenta el total de interacciones, para disminuir el efecto que puedan tener sobre el proceso los usuarios más activos.

Por otro lado, la estimación de los pesos de cada variable con respecto a la contribución que pueda tener en la inferencia de confianza puede convertirse en un factor complejo, que otras aproximaciones han abordado de forma empírica; gracias al uso de PCA, un conjunto de observaciones de variables relacionadas se transforma en un conjunto de observaciones de variables no relacionadas a través de un set de combinaciones lineales para cada tipo de interacción, lo cual no sólo es una forma más objetiva de estimar la contribución de cada variable de interacción, sino que además simplifica el proceso de cálculo del score de confianza. Precisamente, la simplificación del proceso de cálculo del algoritmo se complementó a través de las reducción de los tipos de interacción a procesar pasando de 7 a 4 variables, usando pruebas de *ground truth* con usuarios reales, las cuales arrojaron una precisión del 65 % a partir de los *mensajes en el inbox* (*IM*), los *comentarios* (*C*), los *posts en el muro* (*WP*) y los *tags hacia el destinatario* (*TagsTo*).

Finalmente, se estudiaron dos aproximaciones con miras a incluir el score de confianza en el proceso de generación de las recomendaciones: *promedio ponderado basado en confianza* y *filtrado colaborativo basado en confianza*. Ambos métodos reemplazan el componente de correlación que calcula la similitud entre usuarios, asumiendo que *confianza* y *similitud* están relacionadas, lo cual para los propósitos de la presente tesis doctoral no es una suposición exacta ya que la confianza entre usuarios no es necesariamente un indicador de gustos similares. En este orden de ideas, el algoritmo desarrollado adapta la técnica de filtrado colaborativo basado en confianza reemplazando el componente de correlación de similitud, con uno que incluye una contribución ponderada de confianza y similitud. Específicamente, se calcula la correlación entre usuarios para luego aplicar el algoritmo de inferencia de confianza entre los usuarios del vecindario; aunque alternativamente se podría utilizar el score de confianza para aplicar un filtro en el cual sólo los vecinos más confiables participen en el proceso de recomendación, este método demanda un buen número de conexiones entre los usuarios de la red para conformar el vecindario, lo cual puede ser complejo de implementar en la práctica dada la naturaleza ad-hoc de los escenarios de digital signage. En conclusión, a partir de esta adaptación al algoritmo de filtrado colaborativo clásico se consigue que las recomendaciones se calculen con mayor peso a partir de las opiniones de usuarios con los que el individuo objetivo sostiene alguna relación de confianza, sin dejar de lado la influencia de la similitud en sus preferencias.

ii) *Despliegue de anuncios acorde a las preferencias de un grupo de personas que observa una pantalla pública*: tradicionalmente, la generación de recomendaciones dirigidas a un grupo de personas ha sido abordada desde la perspectiva de técnicas de agregación que básicamente promedian un conjunto de recomendaciones individuales para construir un modelo grupal. El presente trabajo de investigación desarrolló una propuesta innovadora que se centra en la mejora del mecanismo de despliegue de las recomendaciones en entornos de digital signage, más que en el perfeccionamiento de las técnicas de agregación per-se. En este orden de ideas, se propone un esquema de cooperación Smart TV - Smartphone a través del cual el sistema recomienda anuncios a través de dos aproximaciones distintas pero complementarias: recomendaciones grupales que se calculan a través de técnicas de agregación

6.1. Aportes del trabajo de investigación

para ser desplegadas en la pantalla pública y recomendaciones individuales que se calculan a través del algoritmo de filtrado colaborativo basado en confianza, para ser desplegadas en la pantalla de los Smartphones de cada individuo que se encuentra observando la pantalla principal. No obstante, los entornos de publicidad ubicua demandan experiencias más enriquecedoras con los anuncios que van más allá del simple despliegue de información como lo sugiere la publicidad tradicional. En este sentido, se desarrolló un middleware que habilita una comunicación escalable entre la pantalla pública y los dispositivos circundantes, habilitando además capacidades de interacción que puedan involucrar a los usuarios con el conjunto de anuncios más activamente con fines de persuasión. En primera instancia, se analizaron los requisitos que debe reunir un middleware de este tipo desde el punto de vista de su bajo acoplamiento, estabilidad, apertura, simplicidad, interacción concurrente y baja latencia; así mismo, se identificaron las restricciones en el alcance de su implementación desde el punto de vista de la interoperabilidad, escalabilidad, seguridad y el soporte para widgets adicionales.

A partir de estos requisitos, se diseñó un middleware escalable orientado a mensajes que sigue el paradigma *Publisher/Subscriber* para implementar un modelo de comunicación de bajo acoplamiento; igualmente, el diseño elegido a través de una arquitectura en capas, facilita a las aplicaciones desarrolladas por terceros la abstracción de las complejidades relacionadas con los protocolos de comunicación de bajo nivel y el modelo de interacción para el intercambio de mensajes. Estas implementaciones fueron basadas en protocolos abiertos basados en tecnologías estándar como *WebSockets* y *JSON*. Por otro lado, el diseño basado en el paradigma *Publisher/Subscriber* mejora la estabilidad de las conexiones con respecto a otras técnicas basadas en *HTTP* como *long polling*, siendo éste un requisito importante en entornos de digital signage donde múltiples usuarios deben ser soportados. Las pruebas online y offline usando esta aproximación mostraron un comportamiento estable de las conexiones con respecto a experimentos previos realizados con el *Samsung Convergence Framework*.

En otro contexto, el diseño de un API simple sobre una plataforma ampliamente soportada como *Android* posibilita el uso de la mayoría de las capacidades de los dispositivos actuales. A través de extensiones simples, se podría habilitar el uso de características hardware (*GPS*, acelerómetro, giroscopio, etc) para motivar el desarrollo de aplicaciones creativas que enriquezcan la experiencia del usuario; por ejemplo, los eventos del acelerómetro podrían simular el lanzamiento de objetos hacia la pantalla o gestos que midan la fuerza o la velocidad de los movimientos, lo cual podría involucrar a los usuarios en interesantes juegos relacionados con los anuncios desplegados en la pantalla pública. Así mismo, las interacciones concurrentes se facilitan en el middleware gracias a un diseño simple basado en gestos e intercambio de mensajes entre el *Smart TV* y los dispositivos móviles, lo cual mejora la escalabilidad del sistema. Aunque el prototipo desarrollado mostró un buen rendimiento para cuatro usuarios concurrentes, los resultados de los tests offline permiten suponer un buen comportamiento en cuanto al soporte de conexiones simultáneas aún en condiciones extremas. En este sentido, el middleware demostró una baja latencia para el pool de cone-

xiones durante los tests online y offline, lo cual sugiere su aplicabilidad tanto en entornos domésticos como en entornos públicos (digital signage).

iii) *Novedad introducida en las recomendaciones de los anuncios publicitarios:* frecuentemente, la precisión ha sido una de las premisas constantes al momento de evaluar un sistema de recomendaciones y aunque no deja de ser relevante en el dominio de la publicidad ubicua, en este caso la novedad de las recomendaciones de anuncios cobra incluso una relevancia superior. La razón, es que una alta precisión de alguna manera vuelve al sistema de recomendaciones predecible y monótono en el dominio publicitario; con frecuencia, los dueños de las campañas buscan la promoción de nuevos productos y servicios, los cuales a la luz de un sistema de recomendaciones tradicional y muy preciso podrían lucir como falsos positivos; luego el balance entre precisión/novedad es una característica deseable en este tipo de dominios. Aunque a primera vista la novedad percibida parece ser un aspecto meramente cualitativo, la presente tesis doctoral usó el modelo definido por [135] para definir una métrica de novedad basada en la popularidad de los anuncios, que toma en cuenta el *ranking* (posición en la lista) y la relevancia (utilidad para el usuario) como factores clave durante el proceso de recomendación; esta aproximación cobra sentido si se tiene en cuenta que la novedad no está relacionada con la recomendación de ítems desconocidos sino con la recomendación de anuncios nuevos y potencialmente útiles.

En este sentido, se evaluó el modelo propuesto desde una perspectiva de precisión/novedad con algunos hallazgos interesantes: durante los tests offline y online se observó que la introducción del componente de confianza en el algoritmo de recomendación, mejoró la novedad en la lista de anuncios recomendados; sin embargo, se pudo constatar que un algoritmo de filtrado colaborativo 100 % basado en confianza afecta la precisión considerablemente, por lo cual se concluye que es aconsejable mantener la contribución de los componentes de similitud y confianza en el algoritmo de recomendación con el objeto de mejorar el balance precisión/novedad. Adicionalmente, se pudo concluir que la aproximación multi-pantalla definida a través del esquema de cooperación Smart TV - Smartphone propuesto, en el cual se usaron técnicas de agregación para generar las recomendaciones grupales, mejoró el balance precisión/novedad para todo el sistema, obteniendo un mayor grado de novedad en las recomendaciones exhibidas en la pantalla pública (Smart TV) en más del 50 % de los casos durante los experimentos online; igualmente, se pudo constatar que esta tendencia se mantiene aún cuando se introduce el componente de confianza. No obstante, el número de casos donde el valor de novedad de las recomendaciones en el Smart TV supera al valor de novedad en las recomendaciones individuales decrece por el efecto de la introducción del componente de confianza en el algoritmo de filtrado colaborativo. Estos hallazgos comprueban en esencia la hipótesis bajo la cual fue diseñado el esquema de cooperación, al obtener recomendaciones más novedosas partir del modelo grupal (las que se exhiben en el Smart TV) y recomendaciones más precisas a partir del modelo individual (las que se despliegan en la pantalla de los dispositivos móviles). En el mismo sentido, fue posible constatar que la técnica de agregación de *Most Pleasure* exhibe un mejor comportamiento que la técnica de *Least Misery* en cuanto a la novedad de las recomendaciones,

6.2. Trabajos futuros

aunque el efecto fue menos evidente cuando se introdujo el componente de confianza debido al incremento del valor de novedad en las recomendaciones personalizadas entregadas en los dispositivos móviles.

6.2. Trabajos futuros

A continuación se describen algunas limitaciones encontradas durante la realización de la tesis doctoral, que puedan constituirse en puntos de partida para posibles trabajos futuros. Estos puntos pueden analizarse desde dos frentes: i) el filtrado colaborativo basado en confianza y ii) el middleware que sustenta el modelo de cooperación Smart TV - Smartphone.

6.2.1. Filtrado colaborativo basado en confianza

Los tests offline fueron limitados por la ausencia de datasets adecuados para el dominio de la publicidad, pero también por la ausencia de datasets de Facebook con la información de interacción adecuada para llevar a cabo la inferencia de confianza de acuerdo a las características del algoritmo diseñado; en nuestro estudio, los tests offline demandaron la simulación de los datos necesarios para el cálculo del score de confianza. En ese orden de ideas, el dataset desarrollado en el presente trabajo puede ser tomado como un punto de partida que permita complementar la información necesaria de acuerdo a las necesidades de futuras investigaciones, tanto en las características necesarias de la red social Facebook como en lo que respecta al dominio publicitario.

Por otro lado, la operación del algoritmo de inferencia de confianza desarrollado en la presente investigación, demanda el análisis de los siguientes aspectos en la práctica: en primer lugar, el cálculo del score de confianza depende de la disponibilidad de la información de interacción suficiente; por ahora, esto implica la existencia de un grupo homogéneo con suficiente actividad de interacción social entre los participantes, lo cual puede resultar desafiante en entornos de digital signage donde las personas suelen conformar los grupos de manera *ad-hoc*. Para superar esta limitante, durante los experimentos online se realizó un estudio previo sobre la actividad en la red social de los participantes en el experimento para mejorar la conformación de los grupos, pero este es un procedimiento que debe mejorarse de cara a una implementación práctica.

En otro sentido, los continuos cambios en el API de Facebook imponen serias restricciones al momento de implementar un algoritmo de inferencia a partir de la información de interacción en la red en tiempo real. Durante los experimentos, se abordó esta limitación pre-calculando los scores de confianza para el grupo objetivo y almacenándolos en una base de datos para evitar una conexión permanente con Facebook. No obstante, es evidente que esta es una limitación práctica importante.

Finalmente, la presente tesis doctoral no abordó un estudio profundo de técnicas de recomendación grupal, dado el alcance planteado para el trabajo, el cual estuvo dirigido a la

construcción de un modelo de cooperación multipantalla con componentes de recomendación grupales e individuales que permitiera mejorar el balance precisión/novedad, más a partir de una mejora en la estrategia de despliegue que de una mejora en los modelos de recomendación grupal per-se. En este sentido, la presente investigación sienta un precedente en cuanto al análisis para entornos de publicidad ubicua de las técnicas de agregación propuestas por Masthoff [78], más específicamente las técnicas de *Least Misery* y *Most Pleasure*, que pueden constituir un punto de partida importante para futuros trabajos en este tópico.

6.2.2. Middleware que soporta el modelo de cooperación Smart TV - Smartphone

Aunque se seleccionó a Android como base para proporcionar una implementación de referencia para el middleware, la arquitectura propuesta puede ser replicada a otras plataformas; recientemente, una nueva generación de Smart TV boxes abren la posibilidad de extender el middleware a un hardware alternativo como Raspberry Pi u otras opciones de SBC (*Single Board computer*) por ejemplo, lo cual puede resultar atractivo para mercados emergentes.

Por otro lado, aunque los resultados preliminares de los tests offline reflejan la posibilidad de extender el middleware desde entornos domésticos a espacios públicos concurridos, es importante extender el set de pruebas usando pantallas públicas más grandes y un conjunto de Smart TV boxes soportado en mejores características hardware, con el ánimo de estimar con mayor exactitud sus limitaciones en entornos de digital signage más demandantes. En principio, el middleware fue diseñado principalmente para ambientes indoor (tiendas o lugares específicos dentro de un centro comercial), lo cual sugiere que el soporte para redes de displays públicos puede ser otra interesante extensión para el middleware. En otro sentido, la protección de los datos de los usuarios a través de un framework de seguridad que pueda agregarse al middleware luce como otro interesante tópico de investigación para futuros trabajos.

En la práctica, las características del middleware construido abren un universo de posibilidades para el desarrollo de aplicaciones multi-pantalla en otros dominios diferentes al de la publicidad, gracias a su capacidad de transporte de mensajes en tiempo casi real. El artículo presentado en la conferencia *10th European Conference on Technology Enhanced Learning* [136], muestra alguna potencialidad del middleware en entornos como el E-learning; escenarios donde sesiones multimedia orientadas por un profesor en el Smart TV son complementadas por contenido alternativo en las pantallas de los teléfonos móviles de los estudiantes, constituyen otras aproximaciones interesantes que pueden revisarse en próximos trabajos.

Bibliografía

- [1] M. directo, "Google y Facebook liderarán en 2013 los ingresos por publicidad digital." [Online]. Available: <http://www.marketingdirecto.com/actualidad/publicidad/google-y-facebook-lideraran-en-2013-los-ingresos-por-publicidad-digital/>
- [2] "La inversión en publicidad digital alcanza una cifra histórica: 27.500 millones de dólares - Marketing Directo." [Online]. Available: <http://www.marketingdirecto.com/actualidad/digital/la-publicidad-digital-alcanza-una-cifra-historica-27-500-millones-dolares/>
- [3] P. Kotler and K. L. Keller, *Marketing management*. Upper Saddle River, N.J.: Prentice Hall, 2012.
- [4] J. Müller, F. Alt, and D. Michelis, "Pervasive Advertising," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 1-29. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_1
- [5] M. Weiser, "The Computer for the 21st Century," *SIGMOBILE Mob. Comput. Commun. Rev.*, vol. 3, no. 3, pp. 3-11, Jul. 1999. [Online]. Available: <http://doi.acm.org/10.1145/329124.329126>
- [6] S. Boll, A. Schmidt, D. Kern, S. Streng, and P. Holleis, "Magic Beyond the Screen," *IEEE MultiMedia*, vol. 15, no. 4, pp. 8-13, Oct. 2008.
- [7] A. Ranganathan and R. H. Campbell, "Advertising in a Pervasive Computing Environment," in *Proceedings of the 2Nd International Workshop on Mobile Commerce*, ser. WMC '02. New York, NY, USA: ACM, 2002, pp. 10-14. [Online]. Available: <http://doi.acm.org/10.1145/570705.570708>
- [8] U. Stalder, "Digital Out-of-Home Media: Means and Effects of Digital Media in Public Space," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 31-56. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_2
- [9] R. José and J. C. S. Cardoso, "Opportunities and Challenges of Interactive Public Displays as an Advertising Medium," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan.

- 2011, pp. 139–157. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_7
- [10] Frank Jewett, “Why Smart TV is the Next Big Thing,” *Mobile Connect*, vol. 1, no. 2, pp. 1–15, Feb. 2011.
- [11] C. Bauer and S. Spiekermann, “Conceptualizing Context for Pervasive Advertising,” in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 159–183. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_8
- [12] T. Mahmood and F. Ricci, “Improving recommender systems with adaptive conversational strategies,” in *Proceedings of the 20th ACM conference on Hypertext and hypermedia*, ser. HT ’09. New York, NY, USA: ACM, 2009, pp. 73–82. [Online]. Available: <http://doi.acm.org/10.1145/1557914.1557930>
- [13] P. Resnick and H. R. Varian, “Recommender systems,” *Commun. ACM*, vol. 40, no. 3, pp. 56–58, Mar. 1997. [Online]. Available: <http://doi.acm.org/10.1145/245108.245121>
- [14] C. Bauer and S. Spiekermann, “Conceptualizing Context for Pervasive Advertising,” in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 159–183. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_8
- [15] B. D. Carolis, “Adapting News and Advertisements to Groups,” in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 227–246. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_11
- [16] J. C. Cardoso and R. José, “A Framework for Context-Aware Adaptation in Public Displays,” in *Proceedings of the Confederated International Workshops and Posters on On the Move to Meaningful Internet Systems: ADI, CAMS, EI2N, ISDE, IWSSA, MONET, OnToContent, ODIS, ORM, OTM Academy, SWWS, SEMELS, Beyond SAWSDL, and COMBEK 2009*, ser. OTM ’09. Berlin, Heidelberg: Springer-Verlag, 2009, pp. 118–127. [Online]. Available: http://dx.doi.org/10.1007/978-3-642-05290-3_21
- [17] B. J. Fogg, “Persuasive Technology: Using Computers to Change What We Think and Do,” *Ubiquity*, vol. 2002, no. December, Dec. 2002. [Online]. Available: <http://doi.acm.org/10.1145/764008.763957>
- [18] P. v. Waart, I. Mulder, and C. d. Bont, “Meaningful Advertising,” in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 57–81. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_3

BIBLIOGRAFÍA

- [19] W. Reitberger, A. Meschtscherjakov, T. Mirlacher, and M. Tscheligi, "Ambient Persuasion in the Shopping Context," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 309–323. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_15
- [20] S. Vargas and P. Castells, "Rank and Relevance in Novelty and Diversity Metrics for Recommender Systems," in *Proceedings of the Fifth ACM Conference on Recommender Systems*, ser. RecSys '11. New York, NY, USA: ACM, 2011, pp. 109–116. [Online]. Available: <http://doi.acm.org/10.1145/2043932.2043955>
- [21] W. B. Ashton and R. A. Klavans, *Keeping Abreast of Science and Technology: Technical Intelligence for Business*. Columbus, Ohio: Battelle Pr, Mar. 1997.
- [22] "Matheo Analyzer - Patent Searching and Data Analysis." [Online]. Available: <http://www.matheo-software.com/matheo-analyzer/>
- [23] "Publish or Perish." [Online]. Available: <http://www.harzing.com/pop.htm>
- [24] G. Adomavicius and A. Tuzhilin, "Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions," *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 6, pp. 734 – 749, Jun. 2005.
- [25] J. L. Herlocker, J. A. Konstan, A. Borchers, and J. Riedl, "An algorithmic framework for performing collaborative filtering," in *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, ser. SIGIR '99. New York, NY, USA: ACM, 1999, pp. 230–237. [Online]. Available: <http://doi.acm.org/10.1145/312624.312682>
- [26] Q. Li and B. M. Kim, "An approach for combining content-based and collaborative filters," in *Proceedings of the sixth international workshop on Information retrieval with Asian languages - Volume 11*, ser. AsianIR '03. Stroudsburg, PA, USA: Association for Computational Linguistics, 2003, pp. 17–24. [Online]. Available: <http://dx.doi.org/10.3115/1118935.1118938>
- [27] "Apache Mahout: Scalable machine learning and data mining." [Online]. Available: <http://mahout.apache.org/>
- [28] "LensKit Recommender Toolkit." [Online]. Available: <http://lenskit.org/>
- [29] A. M. Rashid, I. Albert, D. Cosley, S. K. Lam, S. M. McNee, J. A. Konstan, and J. Riedl, "Getting to know you: learning new user preferences in recommender systems," in *Proceedings of the 7th international conference on Intelligent user interfaces*, ser. IUI '02. New York, NY, USA: ACM, 2002, pp. 127–134. [Online]. Available: <http://doi.acm.org/10.1145/502716.502737>

- [30] K. Yu, A. Schwaighofer, V. Tresp, X. Xu, and H.-P. Kriegel, "Probabilistic memory-based collaborative filtering," *IEEE Transactions on Knowledge and Data Engineering*, vol. 16, no. 1, pp. 56–69, 2004.
- [31] J. Golbeck, "Generating Predictive Movie Recommendations from Trust in Social Networks," in *Trust Management*, ser. Lecture Notes in Computer Science, K. Stølen, W. H. Winsborough, F. Martinelli, and F. Massacci, Eds. Springer Berlin Heidelberg, Jan. 2006, no. 3986, pp. 93–104. [Online]. Available: http://link.springer.com/chapter/10.1007/11755593_8
- [32] P. Massa and P. Avesani, "Trust-aware Recommender Systems," in *Proceedings of the 2007 ACM Conference on Recommender Systems*, ser. RecSys '07. New York, NY, USA: ACM, 2007, pp. 17–24. [Online]. Available: <http://doi.acm.org/10.1145/1297231.1297235>
- [33] M. J. Pazzani, "A Framework for Collaborative, Content-Based and Demographic Filtering," *Artificial Intelligence Review*, vol. 13, no. 5-6, pp. 393–408, Dec. 1999. [Online]. Available: <http://link.springer.com/article/10.1023/A%3A1006544522159>
- [34] Z. Huang, H. Chen, and D. Zeng, "Applying associative retrieval techniques to alleviate the sparsity problem in collaborative filtering," *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 116–142, Jan. 2004. [Online]. Available: <http://doi.acm.org/10.1145/963770.963775>
- [35] P. Symeonidis, "Content-based Dimensionality Reduction for Recommender Systems," in *Data Analysis, Machine Learning and Applications*, ser. Studies in Classification, Data Analysis, and Knowledge Organization, C. Preisach, P. D. H. Burkhardt, P. D. L. Schmidt-Thieme, and P. D. R. Decker, Eds. Springer Berlin Heidelberg, Jan. 2008, pp. 619–626. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-540-78246-9_73
- [36] D. Billsus and M. J. Pazzani, "Learning Collaborative Information Filters," in *Proceedings of the Fifteenth International Conference on Machine Learning*, ser. ICML '98. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1998, pp. 46–54. [Online]. Available: <http://dl.acm.org/citation.cfm?id=645527.657311>
- [37] R. Burke, "Hybrid Web Recommender Systems," in *The Adaptive Web*, ser. Lecture Notes in Computer Science, P. Brusilovsky, A. Kobsa, and W. Nejdl, Eds. Springer Berlin Heidelberg, Jan. 2007, no. 4321, pp. 377–408. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-540-72079-9_12
- [38] M. Balabanović and Y. Shoham, "Fab: content-based, collaborative recommendation," *Commun. ACM*, vol. 40, no. 3, pp. 66–72, Mar. 1997. [Online]. Available: <http://doi.acm.org/10.1145/245108.245124>
- [39] C. Basu, H. Hirsh, and W. Cohen, "Recommendation as classification: using social and content-based information in recommendation," in *Proceedings of the*

BIBLIOGRAFÍA

- fifteenth national/tenth conference on Artificial intelligence/Innovative applications of artificial intelligence*, ser. AAAI '98/IAAI '98. Menlo Park, CA, USA: American Association for Artificial Intelligence, 1998, pp. 714–720. [Online]. Available: <http://dl.acm.org/citation.cfm?id=295240.295795>
- [40] A. I. Schein, A. Popescul, L. H. Ungar, and D. M. Pennock, "Methods and metrics for cold-start recommendations," in *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*, ser. SIGIR '02. New York, NY, USA: ACM, 2002, pp. 253–260. [Online]. Available: <http://doi.acm.org/10.1145/564376.564421>
- [41] A. Spaeth and M. C. Desmarais, "Combining Collaborative Filtering and Text Similarity for Expert Profile Recommendations in Social Websites," in *User Modeling, Adaptation, and Personalization*, ser. Lecture Notes in Computer Science, S. Carberry, S. Weibelzahl, A. Micarelli, and G. Semeraro, Eds. Springer Berlin Heidelberg, Jan. 2013, no. 7899, pp. 178–189. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-642-38844-6_15
- [42] J. Rongfei, J. Maozhong, and L. Chao, "A new clustering method for collaborative filtering," in *2010 International Conference on Networking and Information Technology (ICNIT)*, 2010, pp. 488–492.
- [43] F. Ricci, L. Rokach, and B. Shapira, "Introduction to Recommender Systems Handbook," in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, Eds. Springer US, Jan. 2011, pp. 1–35. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-387-85820-3_1
- [44] K. Partridge and B. Begole, "Activity-Based Advertising," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 83–101. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_4
- [45] H. Haddadi, P. Hui, T. Henderson, and I. Brown, "Targeted Advertising on the Handset: Privacy and Security Challenges," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 119–137. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_6
- [46] J. Lu, D. Wu, M. Mao, W. Wang, and G. Zhang, "Recommender system application developments: A survey," *Decision Support Systems*, vol. 74, pp. 12 – 32, 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0167923615000627>
- [47] J. L. Herlocker, J. A. Konstan, and J. Riedl, "Explaining Collaborative Filtering Recommendations," in *Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work*, ser. CSCW '00. New York, NY, USA: ACM, 2000, pp. 241–250. [Online]. Available: <http://doi.acm.org/10.1145/358916.358995>

- [48] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, "Evaluating collaborative filtering recommender systems," *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 5–53, Jan. 2004. [Online]. Available: <http://doi.acm.org/10.1145/963770.963772>
- [49] A. Gunawardana, G. Shani, and L. Ungar, "A survey of accuracy evaluation metrics of recommendation tasks," *Journal of Machine Learning Research*, pp. 2935–2962.
- [50] S. M. McNee, J. Riedl, and J. A. Konstan, "Being Accurate is Not Enough: How Accuracy Metrics Have Hurt Recommender Systems," in *CHI '06 Extended Abstracts on Human Factors in Computing Systems*, ser. CHI EA '06. New York, NY, USA: ACM, 2006, pp. 1097–1101. [Online]. Available: <http://doi.acm.org/10.1145/1125451.1125659>
- [51] M. Ge, C. Delgado-Battenfeld, and D. Jannach, "Beyond Accuracy: Evaluating Recommender Systems by Coverage and Serendipity," in *Proceedings of the Fourth ACM Conference on Recommender Systems*, ser. RecSys '10. New York, NY, USA: ACM, 2010, pp. 257–260. [Online]. Available: <http://doi.acm.org/10.1145/1864708.1864761>
- [52] N. Kawamae, "Serendipitous recommendations via innovators," in *Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval*, ser. SIGIR '10. New York, NY, USA: ACM, 2010, pp. 218–225. [Online]. Available: <http://doi.acm.org/10.1145/1835449.1835487>
- [53] M. de Gemmis, P. Lops, G. Semeraro, and C. Musto, "An investigation on the serendipity problem in recommender systems," *Information Processing and Management*, vol. 51, no. 5, pp. 695 – 717, 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0306457315000837>
- [54] T. Kuflik, S. Berkovsky, F. Carmagnola, D. Heckmann, and A. Krüger, *Advances in Ubiquitous User Modelling: Revised Selected Papers*. Springer, Dec. 2009.
- [55] D. Heckmann and A. Krueger, "A User Modeling Markup Language (UserML) for Ubiquitous Computing," in *User Modeling 2003*, ser. Lecture Notes in Computer Science, P. Brusilovsky, A. Corbett, and F. d. Rosis, Eds. Springer Berlin Heidelberg, Jan. 2003, no. 2702, pp. 393–397. [Online]. Available: http://link.springer.com/chapter/10.1007/3-540-44963-9_55
- [56] M. Strohbach, M. Bauer, M. Martin, and B. Hebgen, "Managing Advertising Context," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 185–205. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_9
- [57] Z. D. Champiri, S. R. Shahamiri, and S. S. B. Salim, "A systematic review of scholar context-aware recommender systems," *Expert Systems with Applications*, vol. 42, no. 3, pp. 1743 – 1758, 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417414005569>

BIBLIOGRAFÍA

- [58] T. Hussein, T. Linder, W. Gaulke, and J. Ziegler, "A Framework and an Architecture for Context-Aware Group Recommendations," in *Collaboration and Technology*, ser. Lecture Notes in Computer Science, G. Kolfschoten, T. Herrmann, and S. Lukosch, Eds. Springer Berlin Heidelberg, Jan. 2010, no. 6257, pp. 121–128. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-642-15714-1_10
- [59] K. Partridge and B. Begole, "Activity-Based Advertising," in *Pervasive Advertising*, ser. Human-Computer Interaction Series, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, Jan. 2011, pp. 83–101. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-85729-352-7_4
- [60] A. Schmidt, M. Beigl, and H.-W. Gellersen, "There is more to context than location," *Computers & Graphics*, vol. 23, no. 6, pp. 893–901, Dec. 1999. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S009784939900120X>
- [61] "Word of Mouth Cheat Sheet (Agent Wildfire)." [Online]. Available: <http://es.slideshare.net/agentwildfire/agent-wildfire-cheat-sheet>
- [62] G. Groh and C. Ehmig, "Recommendations in taste related domains: collaborative filtering vs. social filtering," in *Proceedings of the 2007 international ACM conference on Supporting group work*, ser. GROUP '07. New York, NY, USA: ACM, 2007, pp. 127–136. [Online]. Available: <http://doi.acm.org/10.1145/1316624.1316643>
- [63] I. Guy, N. Zwerdling, D. Carmel, I. Ronen, E. Uziel, S. Yoge, and S. Ofek-Koifman, "Personalized recommendation of social software items based on social relations," in *Proceedings of the third ACM conference on Recommender systems*, ser. RecSys '09. New York, NY, USA: ACM, 2009, pp. 53–60. [Online]. Available: <http://doi.acm.org/10.1145/1639714.1639725>
- [64] J. A. Golbeck, "Computing and Applying Trust in Web-based Social Networks," Ph.D. dissertation, University of Maryland at College Park, College Park, MD, USA, 2005, aAI3178583.
- [65] P. Avesani, P. Massa, and R. Tiella, "Moleskiing. it: a trust-aware recommender system for ski mountaineering," *International Journal for Infonomics*, vol. 20, 2005.
- [66] P. Victor, C. Cornelis, M. De Cock, and A. M. Teredesai, "Key figure impact in trust-enhanced recommender systems," *AI Commun.*, vol. 21, no. 2-3, pp. 127–143, Apr. 2008. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1460172.1460178>
- [67] N. Lathia, S. Hailes, and L. Capra, "Trust-Based Collaborative Filtering," in *Trust Management II*, ser. IFIP – The International Federation for Information Processing, Y. Karabulut, J. Mitchell, P. Herrmann, and C. D. Jensen, Eds. Springer US, Jan. 2008, no. 263, pp. 119–134. [Online]. Available: http://link.springer.com/chapter/10.1007/978-0-387-09428-1_8

- [68] J. O'Donovan and B. Smyth, "Trust in Recommender Systems," in *Proceedings of the 10th International Conference on Intelligent User Interfaces*, ser. IUI '05. New York, NY, USA: ACM, 2005, pp. 167–174. [Online]. Available: <http://doi.acm.org/10.1145/1040830.1040870>
- [69] J. Li, C. Sun, and J. Lv, "CTMF: Context-Aware Trust-Based Matrix Factorization with Implicit Trust Network," in *2014 Seventh International Symposium on Computational Intelligence and Design (ISCID)*, vol. 2, Dec. 2014, pp. 387–390.
- [70] L. Sheugh and S. Alizadeh, "A fuzzy aproach for determination trust threshold in recommender systems based on social network," in *2015 9th International Conference on e-Commerce in Developing Countries: With focus on e-Business (ECDC)*, Apr. 2015, pp. 1–5.
- [71] W. Chen and S. Fong, "Social network collaborative filtering framework and online trust factors: A case study on Facebook," in *2010 Fifth International Conference on Digital Information Management (ICDIM)*, Jul. 2010, pp. 266–273.
- [72] E. Bakshy, D. Eckles, R. Yan, and I. Rosenn, "Social Influence in Social Advertising: Evidence from Field Experiments," in *Proceedings of the 13th ACM Conference on Electronic Commerce*, ser. EC '12. New York, NY, USA: ACM, 2012, pp. 146–161. [Online]. Available: <http://doi.acm.org/10.1145/2229012.2229027>
- [73] E. Gilbert and K. Karahalios, "Predicting Tie Strength with Social Media," in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, ser. CHI '09. New York, NY, USA: ACM, 2009, pp. 211–220. [Online]. Available: <http://doi.acm.org/10.1145/1518701.1518736>
- [74] I. Kahanda and J. Neville, "Using Transactional Information to Predict Link Strength in Online Social Networks," in *Third International AAAI Conference on Weblogs and Social Media*, Mar. 2009, many scientific fields analyzing and modeling social networks have focused on manually-collected datasets where the friendship links are sparse (due to the costs of collection) but relatively noise-free (i.e. they indicate strong relationships). In online social networks, where the notion of "friendship" is broader than what would generally be considered in sociological studies, the friendship links are denser but the links contain noisier information (i.e., some weaker relationships). However, the networks also contain additional transactional events among entities (e.g., communication, file transfers) that can be used to infer the true underlying social network. With this aim in mind, we develop a supervised learning approach to predict link strength from transactional information. We formulate this as a link prediction task and compare the utility of attribute-based, topological, and transactional features. We evaluate our approach on public data from the Purdue Facebook network and show that we can accurately predict strong relationships. Moreover, we show that transactional-network features are the most influential features for this task. [Online]. Available: <https://www.aaai.org/ocs/index.php/ICWSM/09/paper/view/213>

BIBLIOGRAFÍA

- [75] K. Panovich, R. Miller, and D. Karger, "Tie strength in question and answer on social network sites," in *Proceedings of the ACM 2012 Conference on Computer Supported Cooperative Work*, ser. CSCW '12. New York, NY, USA: ACM, 2012, pp. 1057–1066. [Online]. Available: <http://doi.acm.org/10.1145/2145204.2145361>
- [76] X. Li, "Interpersonal trust measurements from social interactions in Facebook," Thesis, Montana State University - Bozeman, College of Engineering, 2014. [Online]. Available: <http://scholarworks.montana.edu/xmlui/handle/1/8699>
- [77] A. Jameson, "More than the sum of its members: challenges for group recommender systems," in *Proceedings of the working conference on Advanced visual interfaces*, ser. AVI '04. New York, NY, USA: ACM, 2004, pp. 48–54. [Online]. Available: <http://doi.acm.org/10.1145/989863.989869>
- [78] J. Masthoff, "Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers," *User Modeling and User-Adapted Interaction*, vol. 14, no. 1, pp. 37–85, Feb. 2004. [Online]. Available: <http://link.springer.com/article/10.1023/B%3AUSER.0000010138.79319.fd>
- [79] S. Basu Roy, L. V. Lakshmanan, and R. Liu, "From group recommendations to group formation," in *Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data*, ser. SIGMOD '15. New York, NY, USA: ACM, 2015, pp. 1603–1616. [Online]. Available: <http://doi.acm.org/10.1145/2723372.2749448>
- [80] M. O'Connor, D. Cosley, J. A. Konstan, and J. Riedl, "PolyLens: A Recommender System for Groups of Users," in *ECSCW 2001*, W. Prinz, M. Jarke, Y. Rogers, K. Schmidt, and V. Wulf, Eds. Springer Netherlands, Jan. 2002, pp. 199–218. [Online]. Available: http://link.springer.com/chapter/10.1007/0-306-48019-0_11
- [81] J. F. McCarthy and T. D. Anagnost, "MusicFX: an arbiter of group preferences for computer supported collaborative workouts," in *Proceedings of the 1998 ACM conference on Computer supported cooperative work*, ser. CSCW '98. New York, NY, USA: ACM, 1998, pp. 363–372. [Online]. Available: <http://doi.acm.org/10.1145/289444.289511>
- [82] K. Kabassi, "Personalizing recommendations for tourists," *Telematics and Informatics*, vol. 27, no. 1, pp. 51–66, Feb. 2010. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S073658530900029X>
- [83] L. Ardissono, A. Goy, G. Petrone, M. Segnan, and P. Torasso, "Intrigue: Personalized recommendation of tourist attractions for desktop and hand held devices," *Applied Artificial Intelligence*, vol. 17, no. 8-9, pp. 687–714, 2003. [Online]. Available: <http://www.tandfonline.com/doi/abs/10.1080/713827254>
- [84] L. Guo, J. Shao, K. L. Tan, and Y. Yang, "WhereToGo: Personalized Travel Recommendation for Individuals and Groups," in *2014 IEEE 15th International Conference on Mobile Data Management (MDM)*, vol. 1, Jul. 2014, pp. 49–58.

- [85] J. K. Kim, H. K. Kim, H. Y. Oh, and Y. U. Ryu, "A group recommendation system for online communities," *International Journal of Information Management*, vol. 30, no. 3, pp. 212–219, Jun. 2010. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0268401209001194>
- [86] I. A. Christensen and S. Schiaffino, "Entertainment recommender systems for group of users," *Expert Systems with Applications*, vol. 38, no. 11, pp. 14127–14135, Oct. 2011. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417411007482>
- [87] D. L. Chao, J. Balthrop, and S. Forrest, "Adaptive radio: achieving consensus using negative preferences," in *Proceedings of the 2005 international ACM SIGGROUP conference on Supporting group work*, ser. GROUP '05. New York, NY, USA: ACM, 2005, pp. 120–123. [Online]. Available: <http://doi.acm.org/10.1145/1099203.1099224>
- [88] "Gigaom Samsung acquires second-screen startup MOVL." [Online]. Available: <https://gigaom.com/2013/05/06/samsung-movl-acquisition/>
- [89] "Social TV app Zeebox relaunches as Beamly to lose 'male geekyimage | Technology | The Guardian." [Online]. Available: <http://www.theguardian.com/technology/2014/apr/14/zeebox-beamly-social-tv-app>
- [90] C. Yoon, T. Um, and H. Lee, "Classification of N-Screen Services and its standardization," in *2012 14th International Conference on Advanced Communication Technology (ICACT)*, Feb. 2012, pp. 597–602.
- [91] P. Holleis, G. Broll, and S. Böhm, "Advertising with NFC," in *Workshop on Pervasive Advertising and Shopping, in conjunction with the 8th International Conference on Pervasive Computing (Pervasive 2010), Helsinki, Finland*, 2010. [Online]. Available: <http://141.84.8.93/pubdb/publications/pub/holleis2010pervasiveadvertising/holleis2010pervasiveadvertising.pdf>
- [92] R. José, N. Otero, S. Izadi, and R. Harper, "Instant Places: Using Bluetooth for Situated Interaction in Public Displays," *IEEE Pervasive Computing*, vol. 7, no. 4, pp. 52–57, Oct. 2008. [Online]. Available: <http://dx.doi.org/10.1109/MPRV.2008.74>
- [93] H. Mahato, D. Kern, P. Holleis, and A. Schmidt, "Implicit personalization of public environments using bluetooth," in *CHI '08 Extended Abstracts on Human Factors in Computing Systems*, ser. CHI EA '08. New York, NY, USA: ACM, 2008, pp. 3093–3098. [Online]. Available: <http://doi.acm.org/10.1145/1358628.1358813>
- [94] G. Broll, E. Vodicka, and S. Boring, "Exploring multi-user interactions with dynamic NFC-displays," *Pervasive and Mobile Computing*, vol. 9, no. 2, pp. 242–257, Apr. 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1574119212001186>

BIBLIOGRAFÍA

- [95] R. José, J. Cardoso, F. Alt, S. Clinch, and N. Davies, "Mobile Applications for Open Display Networks: Common Design Considerations," in *Proceedings of the 2Nd ACM International Symposium on Pervasive Displays*, ser. PerDis '13. New York, NY, USA: ACM, 2013, pp. 97–102. [Online]. Available: <http://doi.acm.org/10.1145/2491568.2491590>
- [96] T. Ojala, V. Kostakos, H. Kukka, T. Heikkinen, T. Linden, M. Jurmu, S. Hosio, F. Kruger, and D. Zanni, "Multipurpose Interactive Public Displays in the Wild: Three Years Later," *Computer*, vol. 45, no. 5, pp. 42–49, 2012.
- [97] N. Taylor and K. Cheverst, "Supporting Community Awareness with Interactive Displays," *Computer*, vol. 45, no. 5, pp. 26–32, 2012.
- [98] F. Alt, A. Schmidt, and A. Schmidt, "Advertising on Public Display Networks," *Computer*, vol. 45, no. 5, pp. 50–56, May 2012.
- [99] Q. Chen, F. Malric, Y. Zhang, M. Abid, A. Cordeiro, E. M. Petriu, and N. D. Georganas, "Interacting with Digital Signage Using Hand Gestures," in *Image Analysis and Recognition*, ser. Lecture Notes in Computer Science, M. Kamel and A. Campilho, Eds. Springer Berlin Heidelberg, Jan. 2009, no. 5627, pp. 347–358. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-642-02611-9_35
- [100] R. Hardy, E. Rukzio, M. Wagner, and M. Paolucci, "Exploring expressive nfc-based mobile phone interaction with large dynamic displays," in *Near Field Communication, 2009. NFC'09. First International Workshop on*. IEEE, 2009, pp. 36–41. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5190415
- [101] H. Hu, Y. Wen, H. Luan, T.-S. Chua, and X. Li, "Toward Multiscreen Social TV with Geolocation-Aware Social Sense," *IEEE Multimedia*, vol. 21, no. 3, pp. 10–19, 2014.
- [102] X. Li, T. Xie, and Y. Wen, "Multi-screen Social TV over Cloud-centric Media Platform," in *Proceeding of the 11th Annual International Conference on Mobile Systems, Applications, and Services*, ser. MobiSys '13. New York, NY, USA: ACM, 2013, pp. 481–482. [Online]. Available: <http://doi.acm.org/10.1145/2462456.2465737>
- [103] H. Sato, M. Urata, K. Yoguchi, N. Arakawa, N. Kanamaru, and N. Uchida, "Linking digital signage with mobile phones," in *2011 15th International Conference on Intelligence in Next Generation Networks (ICIN)*, 2011, pp. 86–91.
- [104] "Convergence App API — Samsung Smart TV Apps Developer Forum." [Online]. Available: <http://www.samsungdforum.com/Guide/ref00003/index.html>
- [105] "Samsung MultiScreen SDK." [Online]. Available: <http://multiscreen.samsung.com/>
- [106] I. Fette and A. Melnikov, "The WebSocket Protocol." [Online]. Available: <https://tools.ietf.org/html/rfc6455>

- [107] A. Erbad, M. Blackstock, A. Friday, R. Lea, and J. Al-Muhtadi, "MAGIC Broker: A Middleware Toolkit for Interactive Public Displays," in *Sixth Annual IEEE International Conference on Pervasive Computing and Communications, 2008. PerCom 2008*, Mar. 2008, pp. 509–514.
- [108] J. Ferreira, J. Leitão, and L. Rodrigues, "A-OSGi: A Framework to Support the Construction of Autonomic OSGi-Based Applications," in *Autonomic Computing and Communications Systems*, ser. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, A. V. Vasilakos, R. Beraldí, R. Friedman, and M. Mamei, Eds. Springer Berlin Heidelberg, 2010, no. 23, pp. 1–16. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-642-11482-3_1
- [109] T. Heikkinen, P. Luojus, and T. Ojala, "UbiBroker: Event-based communication architecture for pervasive display networks," in *2014 IEEE International Conference on Pervasive Computing and Communications Workshops (PERCOM Workshops)*, Mar. 2014, pp. 512–518.
- [110] K. Swearingen and R. Sinha, "Beyond algorithms: An HCI perspective on recommender systems," in *ACM SIGIR 2001 Workshop on Recommender Systems*, vol. 13. Citeseer, 2001, pp. 1–11.
- [111] R. R. Sinha and K. Swearingen, "Comparing Recommendations Made by Online Systems and Friends," in *DELOS Workshop: Personalisation and Recommender Systems in Digital Libraries*, 2001.
- [112] N. Kaviani, M. Finke, S. Fels, R. Lea, and H. Wang, "What goes where?: designing interactive large public display applications for mobile device interaction," in *Proceedings of the First International Conference on Internet Multimedia Computing and Service*, ser. ICIMCS '09. New York, NY, USA: ACM, 2009, pp. 129–138. [Online]. Available: <http://doi.acm.org/10.1145/1734605.1734637>
- [113] M. Román, C. Hess, R. Cerqueira, A. Ranganathan, R. H. Campbell, and K. Nahrstedt, "Gaia: a middleware platform for active spaces," *SIGMOBILE Mob. Comput. Commun. Rev.*, vol. 6, no. 4, pp. 65–67, Oct. 2002. [Online]. Available: <http://doi.acm.org/10.1145/643550.643558>
- [114] K. Sachs, S. Kounev, J. Bacon, and A. Buchmann, "Performance Evaluation of Message-oriented Middleware Using the SPECjms2007 Benchmark," *Perform. Eval.*, vol. 66, no. 8, pp. 410–434, Aug. 2009. [Online]. Available: <http://dx.doi.org/10.1016/j.peva.2009.01.003>
- [115] P. Jiang, J. Bigham, E. Bodanese, and E. Clauzel, "Publish/subscribe delay-tolerant message-oriented middleware for resilient communication," *IEEE Communications Magazine*, vol. 49, no. 9, pp. 124–130, Sep. 2011.
- [116] J. Cardoso and M. Barreira, "A web-based toolkit for remote direct manipulation interaction with public displays." ICST, 2014. [Online]. Available: <http://eudl.eu/doi/10.4108/icst.mobiquitous.2014.258067>

BIBLIOGRAFÍA

- [117] D. Cameron, *A Software Engineer Learns HTML5, JavaScript and jQuery: A guide to standards-based web applications*, 1st ed. Cisdal Publishing, Oct. 2013.
- [118] V. Pimentel and B. Nickerson, "Communicating and Displaying Real-Time Data with WebSocket," *IEEE Internet Computing*, vol. 16, no. 4, pp. 45–53, Jul. 2012.
- [119] V. Wang, F. Salim, and P. Moskovits, *The Definitive Guide to HTML5 WebSocket*, 1st ed. Berkely, CA, USA: Apress, 2013.
- [120] P. T. Eugster, P. A. Felber, R. Guerraoui, and A.-M. Kermarrec, "The Many Faces of Publish/Subscribe," *ACM Comput. Surv.*, vol. 35, no. 2, pp. 114–131, Jun. 2003. [Online]. Available: <http://doi.acm.org/10.1145/857076.857078>
- [121] "tavendo/WAMP." [Online]. Available: <https://github.com/tavendo/WAMP>
- [122] E. Gamma, R. Helm, R. Johnson, and J. Vlissides, *Design Patterns: Elements of Reusable Object-Oriented Software*, 1st ed. Reading, Mass: Addison-Wesley Professional, Nov. 1994.
- [123] D. A. Chappell, *Enterprise Service Bus: Theory in Practice*. .°'Reilly Media, Inc.", Jun. 2004.
- [124] M. McPherson, L. Smith-Lovin, and J. M. Cook, "Birds of a Feather: Homophily in Social Networks," *Annual Review of Sociology*, vol. 27, no. 1, pp. 415–444, 2001. [Online]. Available: <http://dx.doi.org/10.1146/annurev.soc.27.1.415>
- [125] J. J. Jones, J. E. Settle, R. M. Bond, C. J. Fariss, C. Marlow, and J. H. Fowler, "Inferring Tie Strength from Online Directed Behavior," *PLoS ONE*, vol. 8, p. 52168, Jan. 2013. [Online]. Available: <http://adsabs.harvard.edu/abs/2013PLoS...852168J>
- [126] V. Podobnik, D. Striga, A. Jandras, and I. Lovrek, "How to calculate trust between social network users?" in *2012 20th International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, Sep. 2012, pp. 1–6.
- [127] M. D. Ekstrand, J. T. Riedl, and J. A. Konstan, "Collaborative Filtering Recommender Systems," *Foundations and Trends® in Human-Computer Interaction*, vol. 4, no. 2, pp. 175–243, 2011.
- [128] P. Massa and P. Avesani, "Trust-Aware Collaborative Filtering for Recommender Systems," in *On the Move to Meaningful Internet Systems 2004: CoopIS, DOA, and ODBASE*, ser. Lecture Notes in Computer Science, R. Meersman and Z. Tari, Eds. Springer Berlin Heidelberg, Jan. 2004, no. 3290, pp. 492–508. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-540-30468-5_31
- [129] P. Victor, M. De Cock, and C. Cornelis, "Trust and recommendations," in *Recommender systems handbook*. Springer, 2011, pp. 645–675.

BIBLIOGRAFÍA

- [130] J. S. Breese, D. Heckerman, and C. Kadie, "Empirical Analysis of Predictive Algorithms for Collaborative Filtering," in *Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence*, ser. UAI'98. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1998, pp. 43–52. [Online]. Available: <http://dl.acm.org/citation.cfm?id=2074094.2074100>
- [131] A. Jameson and B. Smyth, "Recommendation to Groups," in *The Adaptive Web*, ser. Lecture Notes in Computer Science, P. Brusilovsky, A. Kobsa, and W. Nejdl, Eds. Springer Berlin Heidelberg, Jan. 2007, no. 4321, pp. 596–627. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-540-72079-9_20
- [132] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, "Evaluating collaborative filtering recommender systems," *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 5–53, Jan. 2004. [Online]. Available: <http://doi.acm.org/10.1145/963770.963772>
- [133] P. Tran, P. Greenfield, and I. Gorton, "Behavior and performance of message-oriented middleware systems," in *22nd International Conference on Distributed Computing Systems Workshops, 2002. Proceedings*, 2002, pp. 645–650.
- [134] P. Maheshwari and M. Pang, "Benchmarking Message-oriented Middleware: TIB/RV Versus SonicMQ: Research Articles," *Concurr. Comput. : Pract. Exper.*, vol. 17, no. 12, pp. 1507–1526, Oct. 2005. [Online]. Available: <http://dx.doi.org/10.1002/cpe.v17:12>
- [135] P. Castells, S. Vargas, and J. Wang, "Novelty and Diversity Metrics for Recommender Systems: Choice, Discovery and Relevance," Apr. 2011.
- [136] K. Manathunga, D. Hernández-Leo, J. Caicedo, J. J. Ibarra, F. Martínez-Pabón, and G. Ramírez-González, "Collaborative Learning Orchestration Using Smart Displays and Personal Devices," in *Design for Teaching and Learning in a Networked World*, ser. Lecture Notes in Computer Science, G. Conole, T. Klobučar, C. Rensing, J. Konert, and É. Lavoué, Eds. Springer International Publishing, 2015, no. 9307, pp. 596–600, dOI: 10.1007/978-3-319-24258-3_67. [Online]. Available: http://link.springer.com/chapter/10.1007/978-3-319-24258-3_67

Anexo A

Publicaciones

A.1. Anexo A1

Recommending Ads from Trustworthy Relationships in pervasive environments

Francisco Martinez-Pabon¹, Juan Camilo Ospina-Quintero², Gustavo Ramirez-Gonzalez¹, Mario Munoz-Organero³

¹ Grupo de Ingeniería Telemática (GIT), Universidad del Cauca, Popayán, Cauca, Colombia

² Clúster CREATIC, Popayán, Cauca, Colombia

³ Grupo de Aplicaciones y Servicios Telemáticos (GAST), Carlos III University of Madrid, Madrid, Spain

Abstract - The use of pervasive computing technologies for advertising purposes is an interesting emergent field for large, medium and small companies. Although recommender systems have been a traditional solution to decrease users' cognitive effort to find good and personalized items, the classic collaborative filtering needs to include contextual information to be more effective. The inclusion of users' social context information in the recommendation algorithm, specifically trust in other users, may be a mechanism for obtaining ads' influence from other users in their closest social circle. However, there is no consensus about the variables to use during the trust inference process, and its integration into a classic collaborative filtering recommender system deserves a deeper research. On the other hand, the pervasive advertising domain demands a recommender system evaluation from a novelty/precision perspective. The improvement of the precision/novelty balance is a matter not only related to the recommendation algorithm itself, but also a better recommendations display strategy. In this article, we propose a novel approach for a collaborative filtering recommender system based on trust, which was tested throughout a digital signage prototype using a multi-screen scheme for recommendations delivery to evaluate our proposal using a novelty/precision approach.

Keywords: Trust; Collaborative filtering; Multi-screen; Novelty; Social network.

I. INTRODUCTION

Currently, the use of pervasive computing technologies for advertising purposes is an interesting emergent field for large, medium and small companies. One of the marketing areas, advertising, is defined as "any paid form of non-personal presentation and promotion of ideas, goods or services by an identified sponsor" [1]. Frequently, research has focused on advertisement delivery to potential clients through their personal devices (smartphones, tablets or PCs), but public space is still attractive for advertisers, taking into account that 75% of purchase decisions are made at or near the sale place [2]. This field, known as digital signage, is related to digital content display using public screens [3]. However, there are challenges associated with pervasive advertising spaces implementation, which can be analyzed from the following perspectives: First, the

need for personalized content is an issue that can be addressed from recommender systems theory, which provides tools and techniques to provide suggestions in a huge collection of items for a specific user. Specifically, collaborative filtering has been one of the most popular techniques for recommendation purposes; it looks for correlations between users to recognize their affinity and then associates their items evaluations [4]. Nonetheless, the customization process also demands the inclusion of information about the user context. It may be challenging to include all variables that may be considered as "context" in the recommendation algorithm, but one variable is particularly interesting for the advertising domain: the user's "social context". For years, the "word of mouth" has been a powerful technique for marketing purposes, so the inclusion of the user's social context information in the recommendation algorithm (specifically, trust in other users) is a mechanism for obtaining ads' influence from other users in the closest social circle. The traditional collaborative filtering used in recommender systems calculates recommendations based on users' similarities in their ratings, but they are anonymous users. The inclusion of social context information may improve the ads recommendation process with persuasion purposes, considering that 67% of purchase decisions are influenced by the opinions of close others. Although some studies have developed proposals for the inclusion of information in users' social circle, they are frequently based on explicit mechanisms to calculate the trust between users, or they try to infer this same information from the ratings matrix itself. Other approaches define mechanisms to infer trust from social networks, but in most cases, they use proprietary networks or the integration strategy into the recommendation algorithm is not completely defined and tested.

Other main concern is related to the evaluation focus for a recommender system in a pervasive advertising domain. Frequently, the evaluation of recommender systems has been concentrated on precision aspects, but the recommendation novelty may be an aspect even

more relevant for persuasion purposes in advertising. Nonetheless, the improvement of the precision/novelty balance for the recommender system in these cases may be not only a matter of the RS algorithm itself but also a better display strategy issue. In digital signage environments, for example, most public display interaction initiatives do not consider multi-screen approaches, where the content may be distributed between different devices (public screens and smartphones, for example). A screen content replication has been used instead; if this approach combines aggregation techniques for delivering recommendations to groups of people on the main screen with a more robust trust-based recommendation algorithm to deliver custom items on a personal screen (e.g., a smartphone), the balance between the precision and the novelty of the recommendations could improve. On the other hand, several approaches have been defined to measure novelty in different recommender system variants, but a suitable definition for the advertising domain deserves a deeper analysis, which is one of the contributions of this work.

According to the previous analysis, our proposal is focused on the research question *‘How to build a recommender system for pervasive advertising environments supported on a Smart TV – Smartphone framework?’* and the following hypotheses are evaluated: H1: the inclusion of multi-screen capabilities for the recommendations delivery improves the precision/novelty balance; H2: the inclusion of trust information in the collaborative filtering algorithm helps to improve the precision/novelty balance.

The current work develops a new recommender system approach for the advertising domain and makes the following contributions: a trust inference algorithm from social network interaction information; a collaborative filtering recommendation algorithm variant to include trust information during the recommendation process; a digital signage case study definition, where we analyzed the effects of the trust inclusion and multi-screen display strategy over recommendation precision and novelty; and an evaluation scheme derived from the work of Vargas and Castells [5] to measure the novelty in the pervasive advertising domain.

This paper is structured as follows: Section 2 summarizes some related works, section 3 introduces the trust inference algorithm, section 4 describes the strategy to include trust in classic collaborative filtering, section 5 introduces the study case and the features of the implemented prototype, section 6 describes the

results of the experiments, and section 7 outlines conclusions and future work.

II. RELATED WORKS

From pervasive advertising (specifically digital signage) as a field study, we will next summarize some of the most relevant related works, taking into account the main concepts for the current research.

Recommender systems have evolved from data mining and machine learning theories. They have been studied for years as a classic solution to decrease the cognitive effort when there are a huge collection of items the users may explore, independent of a specific domain. Some previous works have compiled the concepts, algorithms and techniques that are more relevant from the recommender systems perspective [6]–[8]. Specifically, collaborative filtering has been one of the most used techniques for recommender systems. It looks for correlations between users to recognize their affinity and then to associate their item evaluations [4]. Some previous works have applied collaborative filtering techniques for advertising purposes [9], including some context variables, but from an explicit approach; the inclusion of trust during recommendation has been less explored for this specific domain.

By and large, the inclusion of trust in recommender systems may be studied from two approaches: explicit trust information from users or trust inferred from users' information. Regarding the first approach, Massa et.al. [10] extended classic recommender system algorithms by including a trust matrix in addition to the ratings matrix to replace the traditional prediction mechanism with an algorithm that calculates the trust propagating in a network, and they used this estimation instead of similarity. Golbeck [11] developed FilmTrust, a website that uses trust inferred from a proprietary social network to offer movie recommendations; the work focuses on determining how to create interfaces to represent the connections between users based on the information they provided by themselves using an algorithm called TidalTrust. Other similar propagation approaches may be seen in [12], [13]. Several other works have developed proposals for trust inference, which are related to the second approach. O'Donovan et.al. [14] extends the traditional User x Item space to a User x Item x Context space, defining a trust matrix inferred from user ratings; a similar proposal was developed by Martín-Vicente et.al. [15] but for expertise and reputation inferences. Other proposals go beyond and try to infer trust from social network information. For example, Chen et.al. [16] proposes a recommendation framework for social networks based on collaborative filtering and trust. In this research, two methods to compute similarity are defined: the first one uses the

similarity of profiles, and the second one is based on people's interactions. From these two values, a unique value is computed and included in the recommendation algorithm; additionally, the authors propose a framework to use the social network Facebook. Bakshy et.al. [17] demonstrated that the interactions between people in a social network are the strongest component of trust inference, and other research works are coherent with this trend, defining frameworks based on interaction information to infer trust. Gilbert et.al. [18] defines a predictive model that maps social media data to tie strength on a dataset of over 2.000 social media ties. As a result, the top 15 predictive variables for trust inference were defined. Other proposals have used similar approaches based on interaction information, and we found several agreements between the reference variables used for trust inference purposes [19] [20], [21]. These works set an important starting point for the current research, and we will expand on some aspects of them in the following sections.

Although the previous works are important advances in trust inference with recommendation purposes, there are some noted gaps with regard to the context of the current research: The pervasive environments demands to capture as much information as possible in an implicit way, and the pervasive advertising domain is not an exception, so trust inference mechanisms from explicit information captured from the users is not attractive for this domain. Although the trust inference from the ratings matrix itself or from an extended User x Item x context matrix is interesting, it still infers information from anonymous users, and there is no assurance these users belong to the closest social circle of the user. According to the previous characterization of the advertising domain, we are interested in inferring information from friends, which is a disadvantage of these techniques and classic collaborative filtering. Therefore, trust inference from social network information seems to be a more suitable solution for the pervasive advertising domain, but the use of proprietary social networks restricts the system scalability for recommendation purposes. On the other hand, there is no consensus about the best variables to infer trust from public social networks such as Facebook, and there is no a clear strategy to include trust information in the recommendation algorithm. These aspects deserve deeper research.

Another important aspect is the evaluation approach to use for a trust-based recommender system in the pervasive advertising domain. One of the more demanding challenges in recommender systems theory is related to metrics fragmentation to evaluate different aspects of these types of systems. Herlocker et.al. [22] developed an empirical analysis for different accuracy

metrics, and Gunawardana et.al. [23] defined a guide for the design of offline experiments with evaluation purposes. Traditionally, precision has been the metric frequently used to evaluate the recommender system, but according to the pervasive advertising domain features, the novelty of the recommendations may be more relevant with persuasion purposes. McNee et.al. [24] proposes new directions to evaluate recommender systems, including the novelty degree. Ge et.al. [25] analyzes the roles of coverage and novelty in the recommendation quality and introduces methods to measure them. Kawamae [26] proposes an algorithm to generate novel recommendations that focuses on the search time that, in the absence of any recommendation, each user would need to find a desirable and novel item by himself, following the hypothesis that the degree of the user's surprise is proportional to the estimated search time. In one of the most interesting works related to novelty measurement, Vargas et.al. [5] developed a formal framework for the definition of novelty and diversity metrics that unifies and generalizes several state-of-the-art metrics. The novelty of a piece of information generally refers to how different it is with respect to "what has been previously seen", by a specific user, as long as the diversity generally applies to a set of items, and is related to how different the items are with respect to each other. This is related to novelty in that when a set is diverse, each item is novel with respect to the rest of the set [5]. This work is used as a starting point for the novelty metric definition in the current research, and its contribution will be described later in detail.

Finally, although the previous works define methods to measure the novelty degree in the recommendation, some of them also define approaches to influence novelty from the recommendation algorithm itself. However, as one of the main hypotheses of the current research, the balance between the precision and the novelty of recommendations may be affected by not only the recommendation algorithm itself but also a better recommendations display strategy. For our specific study case, in the digital signage space design, we consider some works related to the delivery of recommendations to groups of people [27], [28] the Polylens system, a variant of MovieLens [29], MusicFx [30] and Intrigue [31]. Other approaches have defined mechanisms to improve the interaction between users and public displays [32]–[34] or [35]–[38], but a multi-screen approach from the recommender systems perspective and its effect on the balance between precision and novelty has not been explored.

III. INFERRING TRUST FROM SOCIAL NETWORKS

The trust inference concept is strongly related to the homophily concept, a principle that postulates that

people tend to form ties with other people who have similar characteristics [39]. In the most basic sense, this approach can lead to a relationship binary analysis to study a friend/no friend condition. However, this approach is not sufficient to try to infer trust between individuals, as is illustrated in the following example from social network analysis: Suppose User A and User B are friends, and User B and User C are also friends, but User A and User C are only acquaintances. A few days later, User C sends a friendship request to User A, and now they are connected as friends when A accepts the invitation. From the binary approach perspective, there are no differences in the relationship between Users A and B and that between Users A and C, although it is not accurate in practice. Trust inference is a concept that goes beyond a simple “friend/no friend” status analysis, and a new concept arises from the social network analysis to complement this approach: tie strength. The tie strength feature tries to calculate the strength of the relationship between two users when a tie exists between them. Therefore, a tie strength analysis will deliver two possible main results: strong ties (real friends) and weak ties (acquaintances) [40].

Although profile information could provide some level of information about the similarities between people, previous research has found that interaction information is one of the most important sources to try to predict the tie strength. Several techniques may be applied to infer tie strength using diverse technologies: the reciprocity of calls between two mobile phone users, the number of tweets between Twitter users or even the email exchange activity between individuals. Nonetheless, social networks provide a richer space to infer trust from several types of interactions and therefore build a more accurate picture of the trust map of a specific user. Specifically, the current research will use the social network Facebook as a reference. Other works have built proprietary social networks for their experiments, but the study of Facebook may enable a more scalable solution in several domains due to the network’s popularity and use by millions of users.

As a starting point, the current work uses the model proposed by [18] where the authors introduce a predictive model that maps social media data to tie strength on a dataset of over 2.000 social media ties to distinguish between strong and weak ties. Table 1 shows a summary of the predictive model proposal for the variables in different categories.

Table 1. Social media data predictive model

Intensity	Wall words exchanged Wall posts Inbox messages exchanged Status updates
------------------	--

	Comments Likes Tags
Intimacy	Number of friends Days since last communication Wall and inbox intimacy words Appearances together in photos Distance between hometowns Relationship status
Duration	Days since first communication
Reciprocal services	Links exchanged by wall post Applications in common
Structural	Mutual friends Groups in common Similarity of interests Common networks
Emotional support	Number of positive words Number of negative words Gifts exchanged
Social distance	Age difference Occupations difference Educational difference Political and religious difference
Demographic	Gender Number of apps installed Number of inbox messages Number of wall posts Number of photo's comments

Source: [18]

This model defines the top 15 predictive variables; we compare these top 15 results with similar research to obtain a unified set of variables as the starting point for our study (see Fig. 1).

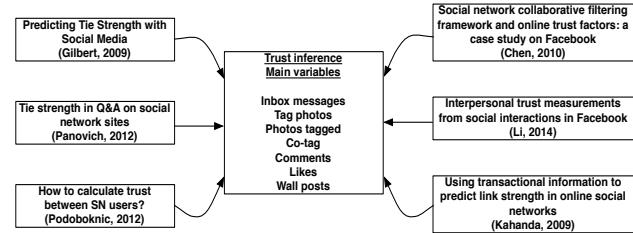


Fig. 1 State of the art: Trust inference from user interactions

According to the previous results, seven variables are selected as a starting point to build the trust inference algorithm between two users, A and B (Table 2).

Table 2. First set of variables to infer trust from Facebook

Exchanged inbox messages Likes (from B to A) Tags to B Tags from B Cotags (posts where both users are tagged together) Comments (from B to A) Wall posts (from B to A)
--

Once we define the first set of variables for trust inference, we define a first approach for the algorithm. The main goal is to build an equation that combines the contribution of this set of variables to calculate a trust

score that can later be integrated into a collaborative recommender filtering technique and keep it as simple as possible for performance purposes. Because trust is not necessarily symmetric, from the work of [41] and according to the simple Multiple Attribute Utility Theory (MAUT), we initially define the trust that User A has in User B as follows:

$$T_{A,B} = \alpha \frac{\sum_{totIM}}{\sum_{totIM}} + \beta \frac{\sum_{Likes}}{\sum_{totLikes}} + \gamma \frac{\sum_{TagsTo}}{\sum_{totTagsTo}} + \delta \frac{\sum_{TagsFrom}}{\sum_{totTagsFrom}} + \varepsilon \frac{\sum_{Cotags}}{\sum_{totCotags}} + \theta \frac{\sum_{C}}{\sum_{totC}} + \phi \frac{\sum_{WP}}{\sum_{totWP}} \quad (1)$$

where $\alpha + \beta + \gamma + \delta + \varepsilon + \theta + \phi = 1$, IM is inbox messages exchanged, C is comments, WP is wall posts, and tot is the prefix for “total”, which is the total amount of items for a particular attribute, i.e., the total amount of inbox messages exchanged by a certain user with all his friends. This normalization makes sense when we consider the interaction frequency between individuals as a clear indicator of trust. For example, suppose user A has the number of interactions with users B and C, as shown in Fig. 2. At first glance, A could trust C more than B, but this is likely because C is a more active user than B, so the activity level of both users must be taken into account. Suppose B has a total of 5 interactions with his friends, and C has 10 interactions. When normalization takes place, we see that almost 60% (3/5) of B interactions are with user A, as long as it only represents the 40% (4/10) for user C, so the effect of the active user is strong. In conclusion, it is important to have a global vision of the network activity and not focus on only the trust inference in the specific pairs’ activity. Other works have used similar approaches for normalization [21], [17].

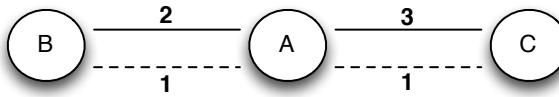


Fig. 2. Users’ interactions in a social network

The final challenge is related to a correct estimation of the weights of each variable in the equation. This is not a trivial issue, and some proposals have used empirical estimations and subjective weights during experimentation [42]. Although it may be an acceptable approach, we looked for a mechanism to combine correlated variables; for example, a tag may trigger a comment or a like, so the numbers of these interactions are related. Accordingly, we choose to adapt the method suggested by Li [21], which applies the principal component analysis (PCA) statistical procedure. PCA uses an orthogonal transformation to convert a set of observations of possibly correlated variables into a set of uncorrelated values by finding a smaller set of linear combinations for the interaction variables. As a result, it

also assigns weights to each independent component, which simplifies the process of calculating the weights according to the contribution of each interaction type. In summary, the process obtains the trust score for each friend of a user u , as follows.

- (1) *Interaction matrix calculation:* For each friend j of User i ($j \in Fi$), an interaction vector is defined, \vec{s}_{ij} ; therefore, each row represents the interaction between friend j and user i , and each column represents a type of interaction ($|Fi|$ rows and 7 columns, one for each interaction variable). Then, the matrix is normalized according to the previous requirements analysis.
- (2) *Covariance matrix calculation:* This step looks for relationships between the set of variables. At the end, we select the eigenvectors that correspond to the largest eigenvalues to obtain a linear principal component combination, as follows:

$$T_j = \sum_{i=1}^m \frac{\lambda_i}{\sum \lambda_m} \times u_i \times Z_{ij} \quad (2)$$

$$Z_{ij}^k = \frac{s_{ij}^k - \bar{x}^k}{\sigma^k}, \bar{x}^k = \frac{\sum x^k}{|Fi|}, \sigma^k = \sqrt{\frac{\sum (s_{ij}^k - \bar{x}^k)^2}{|Fi|-1}} \quad (3)$$

- (3) *Trust score calculation:* The trust score is calculated in two steps:
 - (a) We obtain an initial score according to each principal component contribution (equations 2 and 3).
 - (b) Then, we normalize this score on a -1 to 1 scale to ease the score integration with the recommendation algorithm, as it will be described later (equation 4).

$$\text{Trust score} = \frac{(PCA_{score} - PCA_{min}) \times (Score_{max} - Score_{min})}{PCA_{max} - PCA_{min}} + Score_{min} \quad (4)$$

Once the method is defined to calculate a trust score between users from social network information, we validate this first set of variables to consider the perception of real users regarding the role of each variable in trust inference (see Appendix A).

From the results, we observe that inbox messages, comments and wall posts contribute more to trust inference from the users’ perspective. With these results as a starting point, we performed a ground truth test to calculate the accuracy of the trust inference algorithm. The top ten friends for each participant were computed using the first version, including the seven initial variables, and then the second version, updating the variables according to the users’ perspective tests. Then, participants were asked to rank their calculated top friends from most trusted to least trusted (ground truth).

Finally, we compared the algorithm results for the two versions and the ground truth results using a simple subtraction between the order given by the algorithm and the order given by the users. The results from the second version of the algorithm outperformed those of the first version, so we conducted additional tests to verify whether the tag information inclusion was relevant (Table 3).

Table 3. Ground truth test results for trust inference

Test	Variables	Weighting method	Average	Accuracy
1	Inbox messages, comments, wall posts	PCA	18.4	63%
2	Inbox messages, comments, wall posts, tags to	PCA	17.6	65%

Table 3 shows that although there is no a significant effect by excluding the tags variable, it slightly improves trust inference accuracy. Therefore, the final trust inference equation was defined as follows:

$$T_{A,B} = \alpha \frac{\sum_{i=1}^{IM}}{totIM} + \gamma \frac{\sum_{i=1}^{TagsTo}}{totTagsTo} + \theta \frac{\sum_{i=1}^C}{totC} + \phi \frac{\sum_{i=1}^{WP}}{totWP} \quad (5)$$

IV. TRUST-BASED COLLABORATIVE FILTERING

Usually, recommender systems are used to accurately estimate the degree to which a particular user will like a particular item. Specifically, collaborative filtering is a recommendation algorithm that bases its predictions on the ratings or behavior of other users in the system; i.e., it finds users whose previous ratings are similar to those of the current user and uses those ratings to predict what the current user will like [43]. Traditionally, collaborative filtering recommender systems use a similarity metric to find the user's neighbors, and based on the preferences in that neighborhood, they compute a prediction for an item. The collaborative filtering algorithm is defined by the following aggregation function:

$$p_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) * w_{a,u}}{\sum_{u=1}^n w_{a,u}} \quad (6)$$

where $p_{a,i}$ is the predicted rating for user a on item i , \bar{r}_a represents the average rating for user a , n is the neighborhood, and $w_{a,u}$ is a similarity metric between users, frequently calculated using Pearson's correlation coefficient; other alternatives as Spearman's correlation coefficient are used too. In practice, the traditional collaborative recommender systems exhibit weaknesses related to the sparse nature of data (users typically rate only a small fraction of the available items), the cold start problem (new users have not rated enough items to be linked to similar users) or, even more important, the

algorithm philosophy itself to calculate the similarity with anonymous users. Swearingen et.al [44] and Sinha et.al [45] demonstrate that people tend to rely more on recommendations from people they trust than anonymous users; it therefore is a strong motivation to try to incorporate trust in a classic collaborative filtering technique. In the literature, two strategies are commonly used to include trust in the recommendation algorithm: the trust-based weighted mean and trust-based collaborative filtering.

The first one redefines the recommendation strategy by computing a *trust-based weighted mean*; instead of computing the average rating for item i from the ratings $r_{u,i}$ from all system users u who are already familiar with i , it includes trust values $t_{a,u}$, which reflect the trust degree for raters u . Therefore, the highly trusted users ratings will have more weight.

$$p_{a,i} = \frac{\sum_{u \in n} t_{a,u} r_{u,i}}{\sum_{u \in n} t_{a,u}} \quad (7)$$

Golbeck [46] proposed an algorithm called Tidal Trust, which follows this strategy. According to Goldbeck's research findings, this strategy does not necessarily offer a clear benefit over the classic collaborative filtering, but it improves recommendations for users who disagree with the average rating for a specific item.

The second approach introduces an alternative for the weight calculation ($w_{a,u}$ in equation 6), which tries to infer the weights throughout the relations of the target user in the trust network (using propagation or aggregation techniques). In the equation 6, PCC weights are replaced by trust values $t_{a,u}$:

$$p_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) * t_{a,u}}{\sum_{u=1}^n t_{a,u}} \quad (8)$$

Massa et.al [47] proposes an example for this strategy. According to their findings, the strategy improved the behavior for controversial users, but it also improved the prediction accuracy for cold start users.

Although both approaches show improvement for controversial item rating predictions and cold start recommendations, they replace the correlation component that calculates the similarity between users, likely based on the assumption that trust and similarity are correlated, according to the analysis of Victor et.al [48]. However, we consider that it could not be an exact

assumption as long as the trust between users does not necessarily indicate “similar tastes”. Therefore, we adapted a trust-based collaborative filtering strategy, replacing the similarity correlation component of equation 6 with a new one, including a weighted contribution for similarity and trust.

$$p_{a,i} = \bar{r}_a + \frac{\sum_{u=1}^n (r_{u,i} - \bar{r}_u) * WTS_{a,u}}{\sum_{u=1}^n W_{a,u}} \quad (9)$$

$$WTS_{a,u} = \alpha W_{a,u} + \beta T_{a,u} \quad (10)$$

where $\alpha + \beta = 1$, $T_{a,u}$ represents the trust score between two users, calculated throughout the process illustrated in section 3, and $W_{a,u}$ reflects the correlation between users, calculated by techniques as Pearson’s correlation coefficient or Spearman correlation coefficient; in strict sense, the Pearson’s correlation coefficient have requirements related to the normal distribution of the data, so a non-parametric coefficient as Spearman may be used instead. As a matter of fact, Lathia et.al [49] reported for example, that the precision of the recommender system is not affected significantly by the choice of the similarity measure, so it should not be a concern in the practice.

In simple terms, we calculate the correlation coefficient between users and then the trust score for neighborhood users (see Fig. 3). An alternative could be to use a trust-based filtering technique where the trust values act as a filter, so only the most trustworthy neighbors participate in the recommendation process, as suggested by O’Donovan et.al [50]. However, it demands a highly connected group in the social network to assure an adequate number of users in the neighborhood setup, so this strategy could be more demanding to implement in practice.

In practice, α and β are weights that enable the algorithm calibration to give higher priority to the trust or similarity contribution. We used this feature for different tests during the experimentation using different weights for trust and similarity.

V. TRUST-BASED RECOMMENDATIONS ON DIGITAL SIGNAGE ENVIRONMENTS: AN IMPLEMENTATION APPROACH

Advertising has played an important role in commerce since it originated. Recently, a new paradigm known as pervasive advertising, which refers to the use of pervasive computing technologies for advertising

purposes, has arisen as a promising bet for modern advertisers and consumers. Although most pervasive advertising approaches have been directed to mobile devices (smartphones or tablets), public spaces are also very interesting for the industry, taking into account that the 75% of purchase decisions are made at or near the purchase place [2]. This field, known as digital signage, is related to digital content display using public screens [3]. We implemented a digital signage prototype as a study case to test the new recommendation algorithm based on trust and similarity contributions. This scenario implies the analysis of interesting requirements for the purpose of the current research: First, ads are

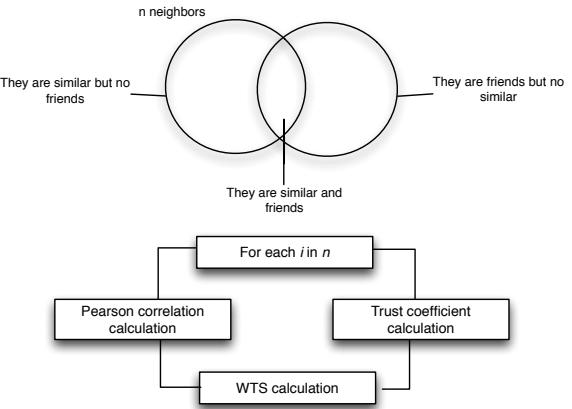


Fig. 3. Trust inclusion in the recommendation algorithm

personalized and adapted to the context; second, ads are addressed to a group of people instead of individuals; finally, the precision of recommendations is a metric frequently evaluated in RS research, but the extent of novelty is also important in the advertising domain as part of the persuasion. Therefore, a balance between precision and novelty is a desirable feature.

Regarding the first requirement, for all variables that may be considered as “context”, likely the most relevant for the advertising domain is the social context. For years, “word of mouth” has been a powerful technique for marketing purposes, so the inclusion of users’ social context information in the recommendation algorithm (specifically, trust in other users) is a mechanism for obtaining ads’ influence on other users in the closest social circle, instead anonymous users, as in traditional collaborative filtering. The inclusion of trust information may improve the ad recommendation process with persuasion purposes, knowing that 67% of purchase decisions are influenced by the opinions of close others.

Regarding the second requirement, the recommendation process for a group of people implies a new set of challenges, which have been addressed in several studies through the use of special aggregation

techniques during the recommendation process; specifically, the techniques described by Masthoff [51] were used as reference. However, the recommendation process improvement in these cases may be not only a matter of the RS algorithm itself but also a better display strategy issue. Most public display interaction initiatives do not consider multi-screen approaches, where the content is distributed between screens in a complementary way; screen content replication has been used instead. This thought is related to the third factor too because a better display strategy may also contribute positively to the novelty perception: By definition, group recommendations displayed on a public screen will be less personalized than recommendations displayed in a personal device (e.g., smartphone or tablet), so they could be more novel for users. This hypothesis is an important contribution of the current research, and it will be analyzed in the following section for the current scenario.

According to the previous description, we implemented a novel electronic alternative for a traditional static ads board, in which people post ads using paper posters; these boards are frequently found in small shops or on academic campuses. The proposed implementation replaces the old board with a new cooperative Smart TV - Smartphone model, where both devices' screens offer ads to users under different but complementary approaches: ads recommendations for group profiles are on public TV screens, and ads recommendations for individual profiles are on smartphones screens. Moreover, the interaction capabilities between the two devices change the static behavior of the traditional board; the basic architecture for the prototype is shown in Fig. 4.

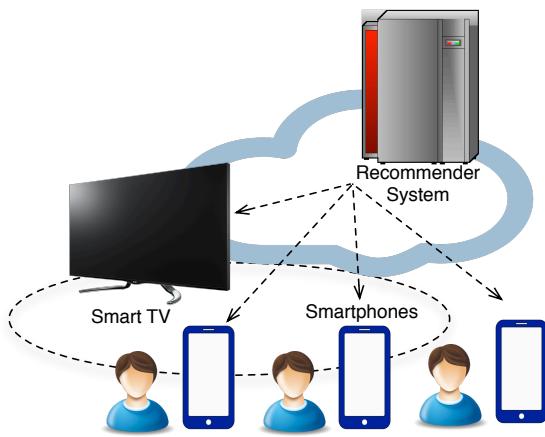


Fig. 4. Prototype basic architecture

In summary, Android applications were developed for mobile phones and Google Smart TV set top box. These applications used a middleware API for interaction management developed for us. The users in front of the

public display log in to the system using a “Login with Facebook feature”. The middleware details are out of the scope of this paper. Please refer to [52] for more details.

Briefly, some of the main functionalities of the implemented prototype are as follows:

i) Ad recommendations for a group of users watching the TV screen: The group of users was limited to four people, basically for usability reasons, taking into account the screen size (42 inches). The recommender calculates the best ad list for the people interacting with the public screen using aggregation techniques; these ads were organized on a list of six ads for each one (see Fig. 5).



Fig. 5. Public display ads screen

ii) Ad recommendations according to individual preferences on the smartphone screen: The recommender calculates the best ad list for each person in front the public display, and it shows the ads on the mobile device screen (see Fig. 6). It uses the recommendation algorithm described in the previous section. The user can obtain detailed information for a particular advertisement and add ads to his or her favorites.



Fig. 6. Mobile device list screen

iii) Basic interaction between mobile device application and public display: The user can go over the ads on the public display using a control pad from the mobile application (Fig. 7); using a tap gesture, the user can obtain detailed information for a particular ad in a public display and watch it on his or her mobile device screen. Each user is identified by a specific color.



Fig. 7. User pad control and ads post

iv) Explicit and implicit ad ratings: users can rate the ads on a public screen or the mobile device list using the “Like” and “No Like” options available in the mobile application user interface. Thanks to the middleware capabilities, it is also possible to generate implicit ratings according to the users’ actions (e.g., request more information about an ad, ignore ads from the screen, add the ad to favorites).

v) Posting ads: Users post ads to the public screen, writing the ad information from the mobile device. The user can use the smartphone’s camera or photo gallery to upload a product picture (Fig. 7).

VI. EXPERIMENTAL RESULTS

We design an experimental framework based on the work of Herlocker et.al [22] to define important considerations during the tests. Specifically, the purpose of the experiments was to evaluate the following hypothesis:

H1: The inclusion of multi-screen cooperation mechanisms improves the precision/novelty balance during the recommendation process.

H2: The inclusion of trust information in the collaborative filtering algorithm improves the precision/novelty balance during the recommendation process.

6.1. Domain considerations

According to the previous description, we tested our recommendation proposal in a pervasive advertising

domain, specifically using a digital signage prototype. Thinking about pervasive advertising features, some important aspects about the domain were considered: The main task for the RS will be to find “some good items”; not all good items are required for advertising purposes. Utility maximization for a user is related not only to good recommendation accuracy but also to some extent of novelty. Recommendation novelty may have higher priority over the first one for advertising purposes. In this sense, although the false positive rate may be considered spam advertising, some of these ads may be novel, so a balance between false positive and novel ads is desirable. Additionally, the false negative rate is particularly relevant for advertisers, as long as they want the items they consider relevant to become recommended ads. Finally, according to the analysis of the advertising domain presented in the Introduction section of this paper, context information in this case was represented by the inclusion of “trust” in the recommendation algorithm, according to the procedures described in the previous sections.

6.2. Dataset considerations

Because our recommender system proposal is based on trust, we required two datasets: one with ratings and another with trust scores. One of the main challenges was the lack of a suitable ratings dataset for the advertising domain, so we decided to build one. We built a Web application where students at the University of Cauca could post and rate ads; then, a set of users participated in interactive sessions using the implemented prototype described previously to improve the dataset information. The first interactions were useful to test the collaborative filtering and the aggregation techniques for the advertising domain. The results were published in [53], [54]. At the end, we completed a dataset with 127 ads, 176 users and 10.128 ratings for the tests.

For the dataset including trust information, the main challenge was to find a homogeneous group of people where each member had at least one connection in Facebook with another member of the group. For the offline tests, we decided to generate this information in a hard-code way based on the users of the rating dataset because our main interest was to see the effect of trust inclusion in the recommendation process; ground truth tests were performed previously for the trust inference algorithm itself, as described in section 3. At the end, we obtained a dataset with 30852 trust connections, as shown in Fig. 8. The graph shows the connections between users, so each pair of connected users shares a

trust value between 0 and 1. The green connections represent higher values of trust as long as red connections represent lower trust values. Regarding the users in the graph, the color and size is given by the node degree; green ones have a higher degree, and red ones have a lower degree.

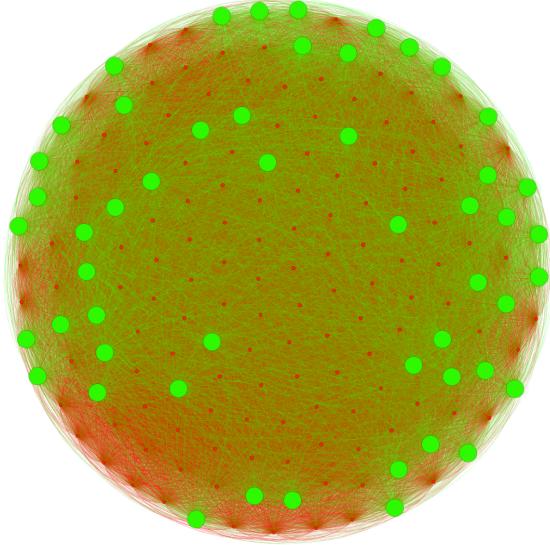


Fig. 8. Trust graph for test group

For the online tests, the task was more challenging because of the requirement of connections between people, as described previously. Several volunteers groups were tested to meet this criterion. Finally, twenty volunteers from Fundación Innovagen in Popayán, met these requirements, and they agreed to participate in the interactive session during the experiment. We used the Graph API Explorer from Facebook to obtain information from the social network with the authorization of each user. All data were anonymous, so only IDs were used for all users, and only the number of interactions was processed without intervention over the message content. Once the interaction information was complete, we computed the trust score between users using the process described in section 3.

Fig. 9 shows the graph representing the communities inside the group. According to the graph, 3 communities were detected: the green community, which is the largest and has the nodes with higher degrees, and the yellow one and the red one, which have nodes with lower degrees. This information allowed us to set up the groups during the interactive experience with the recommender system implemented in the prototype.

Due to the high degrees in the green community, some of its members participated more than once during the experiment.

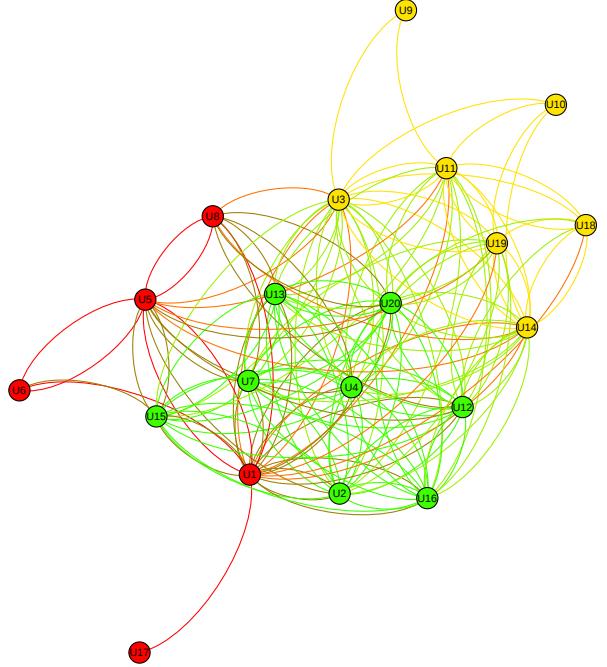


Fig. 9. Fundación Innovagen social graph

6.3. Precision and novelty metrics

As a rule, precision has been the most popular metric for a recommender system evaluation, and it is defined as the ratio of relevant items selected to number of items selected, or the probability that a selected item is relevant.

$$P = \frac{N_r}{N} \quad (11)$$

However, for the purposes of the current research, and according to the advertising domain considerations described previously, it is more interesting to evaluate the recommender system from a precision/novelty perspective. Although several approaches measure the recommendations novelty in the literature, Vargas and Castells [5] proposed an interesting framework for the definition of novelty and diversity metrics that unifies several state-of-the-art metrics. Specifically, this framework supports metrics taking into account the ranking and relevance of the recommended items.

These properties are important for the current research because the interactive nature of our proposal for the specific domain (pervasive advertising), ranking and relevance, take into account how users interact with recommendations (top items receive more attention in each screen list) and user subjectivity (how relevant the item may be for the user).

According to the authors, the novelty of a piece of information generally refers to “how different it is with respect to what has been previously seen” by a user. Nonetheless, in the advertising domain, the effectiveness of ads will be measured not only by “how different they are from previous ads” but also by “how relevant actually they could be for the users”, so the novelty metric should include the influence of these properties during the recommendation process.

In simple terms, the framework is based on three fundamental relationships between users and items (Fig. 10): i) *discovery*, i.e., an item is seen by (or is familiar to) a user; ii) *choice*, i.e., an item is used, picked, selected, or consumed by a user; and iii) *relevance*, i.e., an item is liked by, useful to, or enjoyed by a user. To simplify the model, the authors assume relevant items are always chosen if they are seen, irrelevant items are never chosen and items are discovered independently from their relevance.

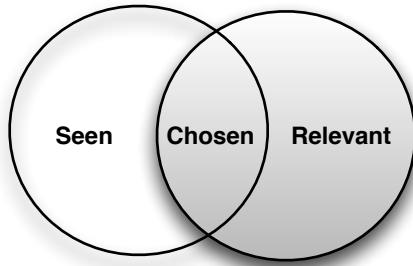


Fig. 10. Novelty model basic principles

In terms of probability distribution, these relations are expressed as:

$$p(\text{choose}) \sim p(\text{seen})p(\text{rel}) \quad (12)$$

Given a ranked list R of items recommended to user u , the novelty can be expressed as:

$$m(R|\theta) = C \sum_{i \in R} p(\text{choose}|i, u, R) nov(i|\theta) \quad (13)$$

where C is a normalizing constant, and θ is a generic context variable to consider different perspectives in the novelty definition. $p(\text{choose}|i, u, R)$ reflects the browsing model grounded on item choice and $nov(i|\theta)$ an item novelty model. For the purposes of the current research, we used a popularity-based item novelty where high novelty values correspond to long-tail items that few users have interacted with, and low novelty values correspond to popular top items, including ranking and relevance factors. According to the domain features, this approach makes sense not only for users but also for advertisers: Frequently, advertisers would like to

promote new products, and they will likely be long-tail items at first for the recommender system. Therefore, a metric of how well the recommender system behaves in these cases could be useful for advertisers. It is expected this behavior improves with the inclusion of a multi-screen approach according to our hypothesis.

In summary, we describe the equations we defined for the novelty metric according to the item-popularity based model:

$$nov(R|u) = C \sum_{i_k \in R} disc(k)p(\text{rel}|i_k, u)(1 - p(\text{seen}|i_k)) \quad (14)$$

In this case, the novelty metric can be read as the expected number of seen relevant recommended items that were not previously seen. The equation includes a ranking component $disc(k)$ that defines a logarithmic decrease according to the item position in the list:

$$disc(k) = \frac{1}{\log_2(k+1)} \quad (15)$$

It also includes a relevance component $p(\text{rel}|i_k, u)$ that can be modeled as a heuristic mapping between rating values and probability of relevance, according to the following function:

$$p(\text{rel}|i, u) \sim \frac{2^{g(u,i)} - 1}{2^{g_{max}}} \quad (16)$$

$$g(u, i) = \max(0, r(u, i) - \tau) \quad (17)$$

g , is a utility function derived from the ratings, where τ represents the indifference rating value according to Breese et.al [55].

6.4. Offline tests

First, we tested the trust-based recommender system using the dataset built from scratch, including ratings and trust scores, as described in section 6.2. The tests were related to hypothesis H2 and were focused on precision and novelty calculations.

To observe the effect of trust on the precision and novelty of the recommendations, we conducted several tests for different values for the contribution of the trust and similarity components of equation 10. The tests ranged from a classic collaborative filtering ($\alpha=1, \beta=0$) to pure trust-based collaborative filtering ($\alpha=0, \beta=1$). Table 4 summarizes the test values for similarity and trust weights.

Fig. 11 shows the precision results for the different tests. It is interesting to observe the poor performance of the recommendation algorithm when a pure trust-based collaborative filtering takes place; this finding is coherent with previous findings of other researchers

[11], [56]. Therefore, a similarity component should be included in the recommendation algorithm to improve the precision results when a trust score influences the recommendation process.

Table 4. Similarity and trust weights for the different tests

Test No.	Trust	Similarity
1	100%	0%
2	90%	10%
3	80%	20%
4	70%	30%
5	60%	40%
6	50%	50%
7	40%	60%
8	30%	70%
9	20%	80%
10	10%	90%
11	0%	100%

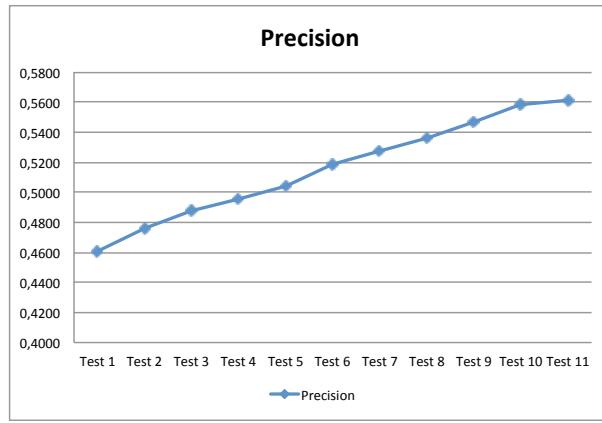


Fig. 11. Recommender system precision results for different similarity-trust values

Although it seems the trust component does not have a meaningful influence on the precision of the recommendation algorithm compared to a classic collaborative filtering approach, it is worth studying the algorithm behavior from a novelty perspective. In this case, we selected 50 random users from the dataset, and we calculated the novelty value, including rank and relevance factors, as described in section 6.3. According to the previous findings, we conducted two tests for a classic collaborative filtering recommender system (test 11; $\alpha=1$, $\beta=0$) and a trust-based recommender system (test 6; $\alpha=0.5$, $\beta=0.5$). Table 5 summarizes the results.

Table 5. Novelty results for the recommender system including and excluding trust

Test	Mean	N	Standard deviation
Traditional recommender system	0.18	50	0.058
Trust-based recommender system	0.23	50	0.070

The mean value suggests that the trust-based recommender system performed better than a classic collaborative filtering from a novelty perspective. We conducted a t-test to determine whether this difference is statistically significant; previously, considering the sample size we ran a Kolmogorov-Smirnov test to check the normal distribution of data getting a p-value of 0.19 for the data associated to the classic algorithm and a p-value of 0.09 for the data associated to the algorithm including trust, so the data follow a normal distribution in both cases. The t-test delivered a p-value < 0.001 , supporting the hypothesis 2. This finding indicates that trust inclusion in the recommendation algorithm improves the precision/novelty balance. However, it is important to contrast these results with the real users' perceptions. This process will be described in the next section.

6.5. Online tests

The tests with real users used the infrastructure of the prototype described in section 5 for the pervasive advertising domain, specifically in a digital signage environment. The purpose of this set of tests was related to hypotheses H1 and H2. As described in section 6.2, one of the main challenges was to find a homogeneous group with enough connections to enable a correct trust inference from the social network. Twenty volunteers from the Fundación Innovagen group met these requirements to perform the test in two sessions: During the first one, the recommender system used a classic collaborative filtering approach ($\alpha=1$, $\beta=0$) to deliver individual recommendations to personal devices (Smartphones) as long as during the second session, the recommender system included a trust and similarity component with equal weights ($\alpha=0.5$, $\beta=0.5$).

A total of 8 groups of 3 people were configured to participate in the experiment according to the social connections graph information. Some of them repeated the experiment because of their relationships with other members of the group. Regarding the group recommendations displayed on the Smart TV, we alternated two aggregation techniques between the groups to test the effect of each one; previous experiments showed a better performance for the chosen techniques [53]. We used the Least Misery aggregation technique for the odd groups (1, 3, 5 and 7); this technique makes a list of ratings with the minimum individual ratings, and the items are recommended based on the rating on that list. Higher rankings indicate less misery, so the group is as happy as its least happy member. We used the Most Pleasure technique for the even groups (2, 4, 6 and 8); in this case, a list of ratings is made with the maximum of the individual ratings. The items are recommended based on the rating on that list, and the higher ranking indicates more pleasure.

Table 6 summarizes the tested algorithm variants for each participant group.

Table 6. Session configuration for online tests

Group	Smart TV Aggregation technique	Smartphone RS algorithm	
		S1	$\alpha=1, \beta=0$
Odd	Least Misery (LM)	S2	$\alpha=0.5, \beta=0.5$
		S1	$\alpha=1, \beta=0$
Even	Most pleasure (MP)	S2	$\alpha=0.5, \beta=0.5$
		S1	$\alpha=1, \beta=0$

During each session, the users interacted with the system for five to ten minutes. As part of the interaction, the users performed several actions, such as browse the ads (on the Smart TV and Smartphone screen), rate ads (on the Smart TV and Smartphone screen), detail a group ad displayed in the Smart TV in the Smartphone screen or add an ad to their favorites list. For the explicit ad-rating task, we used a binary scale (like, no like) because it makes more sense than the classic 1 to 5 stars in the user context. This interaction introduces a novel mechanism to capture implicit ratings for the system throughout a mapping between the user actions and a classic scale from 1 to 5, used during the experiment (Table 7).

At the end of each session, we also captured the users' perception through a short survey in the Smartphone of each user to complete our analysis from a qualitative perspective (see Appendix B).

Table 7. Mapping between user actions and recommender system scale

User interaction	RS Scale
Explicit like	5
Add to favorites	4
Request add information	3
Ignored item from screen	2
Explicit dislike	1

During the experiment, we used Smart TV - Smartphone middleware capabilities to capture logs in JSON format for the activity of the whole sessions, and then, we processed the data. Next, we will introduce the most important results of this experiment.

6.5.1 Trust influence over recommendations precision

Fig. 12 shows the gap between the precision values during the experiment sessions for each group ($\{\alpha=1, \beta=0\} - \{\alpha=0.5, \beta=0.5\}$). The results are coherent with the trend observed during the offline experiments. This difference is always positive; i.e., a higher weight for similarity component (α) will increase the precision value. The observed variation for the precision value was between 0.03 and 0.09 ($p\text{-value} < 0.001$).

According to the results, a positive effect over novelty was expected and it will be analyzed in the next section.

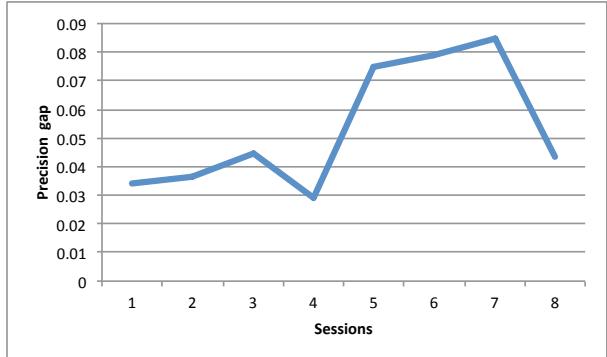


Fig. 12. Precision gap ($\alpha=1, \beta=0 - \alpha=0.5, \beta=0.5$)

6.5.2 Trust influence over recommendation novelty

Table 8 shows a statistical descriptive analysis of the effect of trust introduction in the recommendation algorithm on novelty. The novelty metric included the rank and relevance components, and it was calculated for each session to compare them.

Table 8. Trust influence over recommendations novelty

Session	Mean	Std. dev.	Std. error mean
S1. $\alpha=1, \beta=0$	0.6247	0.0814	0.0192
S2. $\alpha=0.5, \beta=0.5$	0.7072	0.0799	0.0188
			p-value 0.011

According to the results, novelty is positively affected when the trust component is included in the recommendation algorithm, which is coherent with the results observed during the offline tests. Therefore, there is good evidence to support hypothesis H2.

6.5.3 Multi-screen influence over recommendations novelty.

Table 9 shows a statistical descriptive analysis of the effect of the multi-screen approach on novelty. In this case, we calculate the novelty value for the group recommendations in the Smart TV and the personalized recommendations in the Smartphone introducing the trust component ($\alpha=0.5, \beta=0.5$). The novelty metric includes rank and relevance components.

According to the results, the novelty value is larger for the recommendations delivered in the Smart TV for the group profile. Therefore, there is good evidence to support hypothesis H1. However, we conducted a deeper analysis taking into account the trust inclusion and the real users' perception. Fig. 13 shows the results for the number of cases where the group novelty is higher than the individual novelty including and excluding the trust component for different variants of the novelty metric. The trend is coherent with the

previous results because the novelty for group recommendations is higher than the novelty for personalized recommendations in more than the 50% cases, with or without the inclusion of the trust component. However, there is an interesting finding: When the trust component is included, the number of cases where the group recommendations novelty is higher is reduced. A proper justification of this behavior may be analyzed in the user novelty perception results shown in Fig. 14. According to the survey results, it is interesting to observe how the trust component inclusion in the recommendation algorithm improves the novelty perception for the personalized recommendations delivered in the Smartphone. It explains the previous behavior, and it is coherent with the findings described in section 6.5.2. In conclusion, although the trust component has a positive effect on the novelty value for personalized recommendations, the multiscreen approach favors the novelty perception regarding group recommendations. This evidence also supports hypotheses H1 and H2.

Table 9. Multi-screen influence over recommendations novelty

Recommendation strategy	Mean	Std. dev.	Max.	Min.	p-value
Trust-based collaborative filtering (Smartphone)	0.3922	0.1499	0.2456	0.7982	
Aggregation technique (Smart TV)	0.4562	0.1189	0.2997	0.6840	

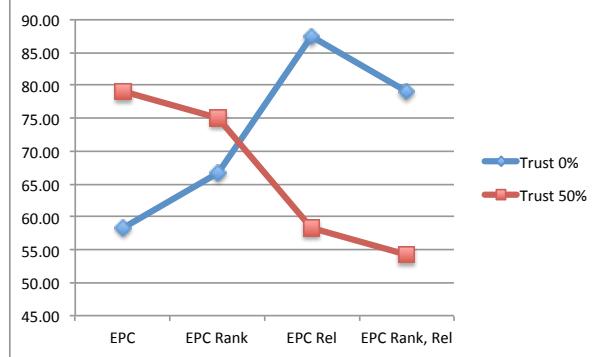


Fig. 13. Cases where group recommendation novelty is greater than personalized recommendation novelty

6.5.4 Aggregation technique influence over recommendation novelty

Initially, we considered the survey results to compare the user perception with the quantitative analysis during the interaction. Fig. 15 shows the novelty trend for the users' perception using a specific aggregation technique during both sessions. The results are coherent with the findings described in the previous section for the multiscreen effect on the recommendation novelty for both

techniques. However, the MP technique seems to exhibit better behavior than the LM technique, specifically during the second session (trust 50%), but because the statistical evidence we found was not enough ($p = 0.558$), we went a step further with the quantitative analysis.

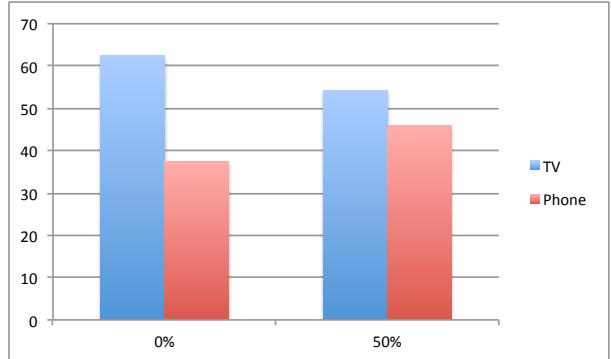
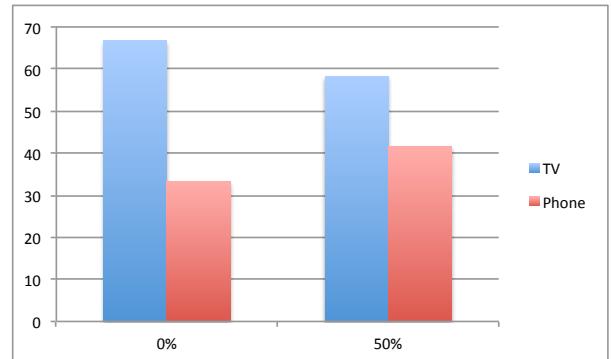
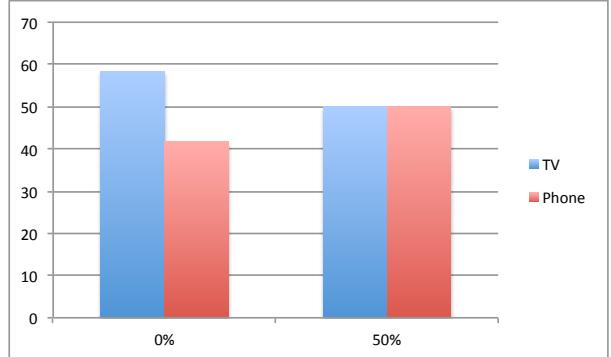


Fig. 14. Users' novelty perception when trust component is included



a) LM



b) MP

Fig. 15. Users' novelty perception per aggregation technique

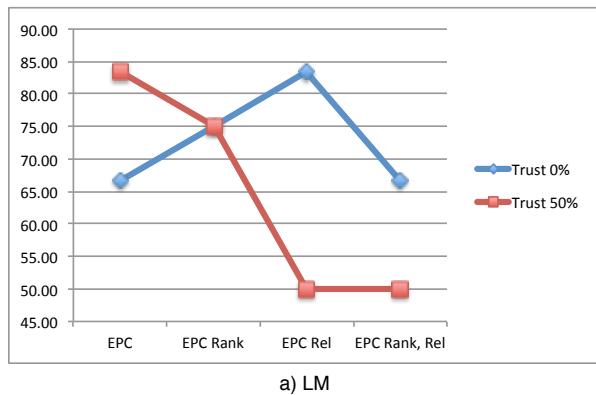
Table 10 shows a statistical descriptive analysis of the effect of the aggregation technique change on the group recommendation novelty. The novelty metric included the rank and relevance components, and it was calculated for the sessions where the Least Misery or Most Pleasure techniques were used.

Table 10. Aggregation technique influence over recommendation novelty

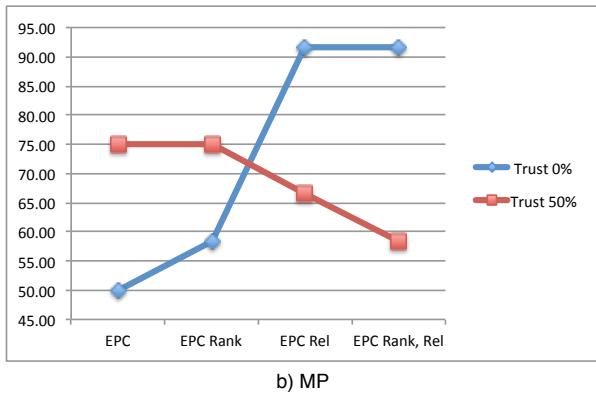
Aggregation technique	Mean	Std. dev.	Std. error mean
LM	0.4046	0.1133	0.0327
MP	0.5076	0.1046	0.0302
p-value	0.03		

According to the results, there is evidence that the aggregation technique affects the novelty value for the group recommendations, with a slight positive effect for the Most Pleasure technique.

Fig. 16 shows the trend when the two aggregation techniques are compared taking into account the number of cases where the group recommendation novelty value overcomes the personalized recommendation novelty value. As expected, the MP technique exhibits a better behavior than LM including the ranking and relevance factors in the novelty metric, but the effect is less evident when the trust component is enabled in the recommendation algorithm because the novelty value increases for personalized recommendation, according to the analysis of section 6.6.2.



a) LM



b) MP

Fig. 16. Novelty per aggregation technique (group novelty value > individual novelty value)

VII. CONCLUSIONS

In this work, we developed a proposal for a collaborative filtering recommender system based on trust. The trust component was included in the recommendation algorithm throughout two phases: i) an algorithm calculated a trust score from social network interaction information (Facebook was used for this purpose); specifically, we defined four variables from the state-of-the-art and ground truth tests for the algorithm: inbox messages, tags to user, comments and wall posts. ii) Then, the recommendation algorithm calculated the recommendations based on the similarity and trust components between users. The algorithm was designed to modify the similarity and trust contributions, which eased the algorithm calibration for specific practical requirements.

We studied the algorithm behavior in the pervasive advertising domain, specifically in a digital signage prototype. This domain study let us think about the recommender system not only from the algorithms perspective itself but also from the recommendations display strategy. A multi-screen advertising prototype was designed and implemented to evaluate the proposed recommender framework using custom datasets and real users' perception. Traditionally, recommender systems are evaluated from a precision perspective, but the recommendations novelty is a relevant aspect, specifically for the advertising domain. We used the model proposed by [5] to define a novelty metric based on an item popularity approach that takes into account ranking and relevance factors during the recommendation process; it does make sense because the novelty is related not to recommending unknown items but to recommending novel and potentially useful items.

We evaluated our framework from a precision/novelty perspective with interesting findings: We found during the offline and online tests that the trust component introduction improved the novelty for the recommendations. However, a pure trust-based algorithm affected the precision adversely, so it is advisable to do a combination of similarity and trust components to keep a better precision/novelty balance. We also found that a multi-screen approach using aggregation techniques to generate group recommendations improved the precision/novelty balance for the whole system; we obtained higher novelty value for Smart TV recommendations in more than the 50% of the cases during the online experiments. Additionally, we found that this trend remained unalterable when the trust component was introduced; nonetheless, the number of cases where the Smart TV recommendations' novelty value was higher decreased because the users perceived an increase in the

novelty of the Smartphone recommendations, due to the trust component effect in the recommendation algorithm.

Finally, we demonstrated that the aggregation technique influenced the novelty for group recommendations; in this case, the Most Pleasure technique exhibited better behavior than the Least Misery technique, but the effect was less evident when the trust component was introduced due to the novelty increase in the personalized recommendations displayed in the Smartphone.

VIII. FUTURE WORK

Next, we will address the limitations found during the study that can be used as a starting point for future work. First, the offline tests were limited by the absence of suitable datasets for the advertising domain but also Facebook datasets with the right information to infer trust according to our algorithm features. The dataset we built for ad information may be used as a starting point for gathering more information and for building a robust dataset with test purposes. It could be complemented with Facebook dataset information that enables a trust score calculation. We used a simulation for the trust score during the offline tests.

In practice, the operation of our proposed algorithm requires taking into account important considerations: First, the trust inference depends on the availability of sufficient interaction information. For now, it implies having a homogeneous group with enough social activity between participants, which may be challenging in digital signage environments where people may join a group in an ad-hoc way. For online experiments, we conducted a previous study of the social activity between the members of the target group to get accurate results, but it is a feature to improve in practice. Additionally, the frequent changes to the Facebook API impose several restrictions to implement trust inference algorithms from the social network information in real time. Our approach was to pre-calculate the trust scores for the known group and store them in a database to avoid a permanent connection to Facebook, but again, it could be problematic for ad-hoc digital signage environments.

Finally, we restricted the number of participants to four people during the experimentation of our multi-screen recommender system approach because of usability issues. The number of participants depends on several factors, such as the main screen size, the hardware capabilities to support the middleware interaction information flow and the recommender system operation itself. Although we reached some conclusions as a starting point in our previous work [52], these

aspects should be carefully analyzed during a practical implementation of the system.

IX. APPENDICES

Appendix A Users perception about trust inference variables

We conducted a survey with 57 anonymous volunteers from the SmartSoft Play company (we used an intranet web page and all of them were familiar with technology), and we asked them to select which variables better represented trust in another person on Facebook. We simplified the subset to 5 variables. (All tag-related variables were represented simply as tags.) The results are summarized in Fig. 17 for a total of 145 votes for the 5 variables.

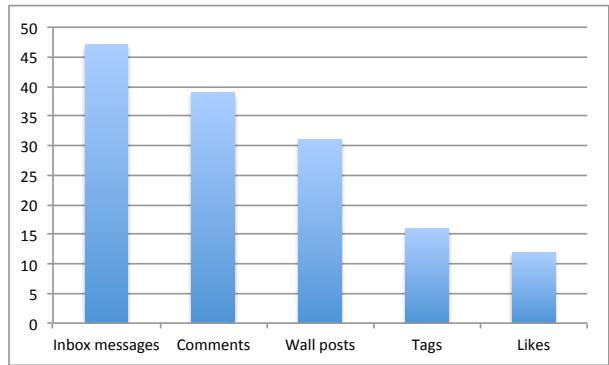


Fig. 17. Trust inference set of variables validation.

Appendix B Users perception survey about recommender system precision and novelty

Table 11. Users perception survey

Session #
1. What screen offered you recommendations closer to your personal preferences?
<input type="radio"/> Smart TV
<input type="radio"/> Smartphone
2. What screen offered you more novel recommendations (likely unknown but interesting for you)?
<input type="radio"/> Smart TV
<input type="radio"/> Smartphone

X. ACKNOWLEDGMENTS

This work was supported by the University of Cauca through project VRI 3593 “SMARTA: Modelo para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone”. Juan Camilo Ospina is funded by the Cluster CREATIC and Colciencias young researcher program through the project “ScoRPICUS: Sistema de recomendaciones para entornos de publicidad ubicua apoyado en información contextual y redes sociales”.

Francisco Martinez is funded by Colciencias Doctoral scholarship N. 567. Part of this work was conducted at Carlos III University of Madrid, Spain, where Francisco Martinez and Juan Camilo Ospina were visiting scholars in 2014 and 2015, respectively. Special thanks to Fundación Innovagen, SmartSoft Play and University of Cauca volunteers for their valuable support during the experiments.

XI. REFERENCES

- [1] J. Müller, F. Alt, and D. Michelis, "Pervasive Advertising," Springer London, 2011, pp. 1–29.
- [2] C. Bauer and S. Spiekermann, "Conceptualizing Context for Pervasive Advertising," in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 159–183.
- [3] U. Stalder, "Digital Out-of-Home Media: Means and Effects of Digital Media in Public Space," in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 31–56.
- [4] T. Mahmood and F. Ricci, "Improving recommender systems with adaptive conversational strategies," in *Proceedings of the 20th ACM conference on Hypertext and hypermedia*, New York, NY, USA, 2009, pp. 73–82.
- [5] S. Vargas and P. Castells, "Rank and Relevance in Novelty and Diversity Metrics for Recommender Systems," in *Proceedings of the Fifth ACM Conference on Recommender Systems*, New York, NY, USA, 2011, pp. 109–116.
- [6] J. L. Herlocker, J. A. Konstan, A. Borchers, and J. Riedl, "An algorithmic framework for performing collaborative filtering," in *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, New York, NY, USA, 1999, pp. 230–237.
- [7] Q. Li and B. M. Kim, "An approach for combining content-based and collaborative filters," in *Proceedings of the sixth international workshop on Information retrieval with Asian languages - Volume 11*, Stroudsburg, PA, USA, 2003, pp. 17–24.
- [8] G. Adomavicius and A. Tuzhilin, "Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions," *IEEE Trans. Knowl. Data Eng.*, vol. 17, no. 6, pp. 734–749, Jun. 2005.
- [9] B. D. Carolis, "Adapting News and Advertisements to Groups," in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 227–246.
- [10] P. Massa, I. Fbk, P. Avesani, and I. Fbk, "Trust-aware Recommender Systems."
- [11] J. Golbeck, "Generating Predictive Movie Recommendations from Trust in Social Networks," 2006, pp. 93–104.
- [12] P. Avesani, P. Massa, and R. Tiella, "Moleskiing.it: a trust-aware recommender system for ski mountaineering," *Int. J. Infonomics*, vol. 20, 2005.
- [13] P. Victor, C. Cornelis, M. De Cock, and A. M. Teredesai, "Key figure impact in trust-enhanced recommender systems," *AI Commun.*, vol. 21, no. 2–3, pp. 127–143, Apr. 2008.
- [14] J. O'Donovan and B. Smyth, "Trust in recommender systems," in *Proceedings of the 10th international conference on Intelligent user interfaces*, New York, NY, USA, 2005, pp. 167–174.
- [15] M. I. Martín-Vicente, A. Gil-Solla, M. Ramos-Cabrera, Y. Blanco-Fernández, and M. López-Nores, "Semantic inference of user's reputation and expertise to improve collaborative recommendations," *Expert Syst. Appl.*, vol. 39, no. 9, pp. 8248–8258, Jul. 2012.
- [16] W. C. W. Chen and S. Fong, "Social network collaborative filtering framework and online trust factors: A case study on Facebook," *Digit. Inf. Manag. ICDIM 2010 Fifth Int. Conf. On*, pp. 266–273, 2010.
- [17] E. Bakshy, D. Eckles, R. Yan, and I. Rosenn, "Social Influence in Social Advertising: Evidence from Field Experiments," in *Proceedings of the 13th ACM Conference on Electronic Commerce*, New York, NY, USA, 2012, pp. 146–161.
- [18] E. Gilbert and K. Karahalios, "Predicting Tie Strength with Social Media," in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, New York, NY, USA, 2009, pp. 211–220.
- [19] I. Kahanda and J. Neville, "Using Transactional Information to Predict Link Strength in Online Social Networks," in *Third International AAAI Conference on Weblogs and Social Media*, 2009.
- [20] K. Panovich, R. Miller, and D. Karger, "Tie Strength in Question & Answer on Social Network Sites," in *Proceedings of the ACM 2012 Conference on Computer Supported Cooperative Work*, New York, NY, USA, 2012, pp. 1057–1066.
- [21] X. Li, "Interpersonal trust measurements from social interactions in Facebook," Thesis, Montana State University - Bozeman, College of Engineering, 2014.
- [22] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, "Evaluating collaborative filtering recommender systems," *ACM Trans Inf Syst*, vol. 22, no. 1, pp. 5–53, Jan. 2004.
- [23] A. Gunawardana, G. Shani, and L. Ungar, "A survey of accuracy evaluation metrics of recommendation tasks," *J. Mach. Learn. Res.*, pp. 2935–2962.
- [24] S. M. McNee, J. Riedl, and J. A. Konstan, "Being Accurate is Not Enough: How Accuracy Metrics Have Hurt Recommender Systems," in *CHI '06 Extended Abstracts on Human Factors in Computing Systems*, New York, NY, USA, 2006, pp. 1097–1101.
- [25] M. Ge, C. Delgado-Battenfeld, and D. Jannach, "Beyond accuracy: evaluating recommender systems by coverage and serendipity," in *Proceedings of the fourth ACM conference on Recommender systems*, New York, NY, USA, 2010, pp. 257–260.
- [26] N. Kawamae, "Serendipitous recommendations via innovators," in *Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval*, New York, NY, USA, 2010, pp. 218–225.
- [27] A. Jameson, "More than the sum of its members: challenges for group recommender systems," in *Proceedings of the working conference on Advanced visual interfaces*, New York, NY, USA, 2004, pp. 48–54.
- [28] J. Masthoff, "Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers," *User Model. User-Adapt. Interact.*, vol. 14, no. 1, pp. 37–85, Feb. 2004.
- [29] M. O'Connor, D. Cosley, J. A. Konstan, and J. Riedl, "PolyLens: A Recommender System for Groups of Users," in *ECSCW 2001*, W. Prinz, M. Jarke, Y. Rogers, K. Schmidt, and V. Wulf, Eds. Springer Netherlands, 2002, pp. 199–218.
- [30] J. F. McCarthy and T. D. Anagnost, "MusicFX: an arbiter of group preferences for computer supported collaborative workouts," in *Proceedings of the 1998 ACM conference on Computer supported cooperative work*, New

- York, NY, USA, 1998, pp. 363–372.
- [31] K. Kabassi, “Personalizing recommendations for tourists,” *Telemat. Inform.*, vol. 27, no. 1, pp. 51–66, Feb. 2010.
- [32] P. Holleis, G. Broll, and S. Böhm, “Advertising with NFC,” in *Workshop on Pervasive Advertising and Shopping, in conjunction with the 8th International Conference on Pervasive Computing (Pervasive 2010), Helsinki, Finland*, 2010.
- [33] R. Jose, N. Otero, S. Izadi, and R. Harper, “Instant Places: Using Bluetooth for Situated Interaction in Public Displays,” *IEEE Pervasive Comput.*, vol. 7, no. 4, pp. 52–57, 2008.
- [34] H. Mahato, D. Kern, P. Holleis, and A. Schmidt, “Implicit personalization of public environments using bluetooth,” in *CHI ’08 Extended Abstracts on Human Factors in Computing Systems*, New York, NY, USA, 2008, pp. 3093–3098.
- [35] N. Otero and R. José, “Worth and Human Values at the Centre of Designing Situated Digital Public Displays,” *Int. J. Adv. Pervasive Ubiquitous Comput.*, vol. 1, no. 4, pp. 1–13, 34 2009.
- [36] P. Santos, F. R. Ribeiro, and J. Metrolho, “Using pervasive computing technologies to deliver personal and public ads in public spaces,” in *2012 7th Iberian Conference on Information Systems and Technologies (CISTI)*, 2012, pp. 1–6.
- [37] D. Michelis and H. Send, “Engaging Passers-by with Interactive Screens-A Marketing Perspective.,” in *GI Jahrestagung*, 2009, pp. 3875–3881.
- [38] J. C. Cardoso and R. José, “A Framework for Context-Aware Adaptation in Public Displays,” in *Proceedings of the Confederated International Workshops and Posters on On the Move to Meaningful Internet Systems: ADI, CAMS, EI2N, ISDE, IWSSA, MONET, OnToContent, ODIS, ORM, OTM Academy, SWWS, SEMELS, Beyond SAWSLD, and COMBEK 2009*, Berlin, Heidelberg, 2009, pp. 118–127.
- [39] M. McPherson, L. Smith-Lovin, and J. M. Cook, “Birds of a Feather: Homophily in Social Networks,” *Annu. Rev. Sociol.*, vol. 27, no. 1, pp. 415–444, 2001.
- [40] J. J. Jones, J. E. Settle, R. M. Bond, C. J. Fariss, C. Marlow, and J. H. Fowler, “Inferring Tie Strength from Online Directed Behavior,” *PLoS ONE*, vol. 8, p. 52168, Jan. 2013.
- [41] W. Chen and S. Fong, “Social network collaborative filtering framework and online trust factors: A case study on Facebook,” in *2010 Fifth International Conference on Digital Information Management (ICDIM)*, 2010, pp. 266–273.
- [42] V. Podobnik, D. Striga, A. Jandras, and I. Lovrek, “How to calculate trust between social network users?,” in *2012 20th International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, 2012, pp. 1–6.
- [43] M. D. Ekstrand, J. T. Riedl, and J. A. Konstan, “Collaborative Filtering Recommender Systems,” *Found. Trends® Hum.-Comput. Interact.*, vol. 4, no. 2, pp. 175–243, 2011.
- [44] K. Swearingen and R. Sinha, “Beyond algorithms: An HCI perspective on recommender systems,” in *ACM SIGIR 2001 Workshop on Recommender Systems*, 2001, vol. 13, pp. 1–11.
- [45] R. R. Sinha and K. Swearingen, “Comparing Recommendations Made by Online Systems and Friends.,” in *DELOS workshop: personalisation and recommender systems in digital libraries*, 2001, vol. 106.
- [46] J. Golbeck, “Generating Predictive Movie Recommendations from Trust in Social Networks,” in *Trust Management*, K. Stølen, W. H. Winsborough, F. Martinelli, and F. Massacci, Eds. Springer Berlin Heidelberg, 2006, pp. 93–104.
- [47] P. Massa and P. Avesani, “Trust-aware Recommender Systems,” in *Proceedings of the 2007 ACM Conference on Recommender Systems*, New York, NY, USA, 2007, pp. 17–24.
- [48] P. Victor, M. De Cock, and C. Cornelis, “Trust and recommendations,” in *Recommender systems handbook*, Springer, 2011, pp. 645–675.
- [49] N. Lathia, S. Hailes, and L. Capra, “The Effect of Correlation Coefficients on Communities of Recommenders,” in *Proceedings of the 2008 ACM Symposium on Applied Computing*, New York, NY, USA, 2008, pp. 2000–2005.
- [50] J. O’Donovan and B. Smyth, “Trust in Recommender Systems,” in *Proceedings of the 10th International Conference on Intelligent User Interfaces*, New York, NY, USA, 2005, pp. 167–174.
- [51] J. Masthoff, “Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers,” *User Model. User-Adapt. Interact.*, vol. 14, no. 1, pp. 37–85, Feb. 2004.
- [52] F. Martinez-Pabon, J. Caicedo-Guerrero, J. J. Ibarra-Samboni, G. Ramirez-Gonzalez, Hernández-Leo, “Smart TV-Smartphone Multiscreen Interactive Middleware for Public Displays,” *Sci. World J.*, vol. 2015, p. e534949, Apr. 2015.
- [53] F. Martinez-Pabon, J. C. Ospina-Quintero, V. Garzon-Marin, A. Chantre-Astaiza, M. Muñoz-Organero, and G. Ramirez-Gonzalez, “Enriching Public Displays Ads Recommendations Using an Individual: Group Cooperation Model,” in *Proceedings of The International Symposium on Pervasive Displays*, New York, NY, USA, 2014, p. 186:186–186:187.
- [54] F. Martinez-Pabon, J. Caicedo-Guerrero, J. J. Ibarra-Samboni, G. Ramirez-Gonzalez, M. Muñoz-Organero, and A. Chantre-Astaiza, “Smart TV – Smartphone Cooperation Model on Digital Signage Environments: An Implementation Approach,” presented at the MOBILITY 2014, The Fourth International Conference on Mobile Services, Resources, and Users, 2014, pp. 25–31.
- [55] J. S. Breese, D. Heckerman, and C. Kadie, “Empirical Analysis of Predictive Algorithms for Collaborative Filtering,” in *Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence*, San Francisco, CA, USA, 1998, pp. 43–52.
- [56] J. O’Donovan and B. Smyth, “Trust in recommender systems,” *Proc. 10th Int. Conf. Intell. User Interfaces IUI 05*, vol. 05pages, p. 167, 2005.

A.2. Anexo A2

A.2. Anexo A2

Research Article

Smart TV-Smartphone Multiscreen Interactive Middleware for Public Displays

Francisco Martinez-Pabon,¹ Jaime Caicedo-Guerrero,¹ Jhon Jairo Ibarra-Samboni,¹ Gustavo Ramirez-Gonzalez,¹ and Davinia Hernández-Leo²

¹Telematics Engineering Group, University of Cauca, Street 5 No. 4-70, 19002 Popayán, Colombia

²Serra Húnter, ICT Department, Pompeu Fabra University, C/Roc Boronat 138, 08018 Barcelona, Spain

Correspondence should be addressed to Francisco Martinez-Pabon; fomarti@unicauca.edu.co

Received 23 December 2014; Revised 27 February 2015; Accepted 18 March 2015

Academic Editor: Jorge C. S. Cardoso

Copyright © 2015 Francisco Martinez-Pabon et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

A new generation of public displays demands high interactive and multiscreen features to enrich people's experience in new pervasive environments. Traditionally, research on public display interaction has involved mobile devices as the main characters during the use of personal area network technologies such as Bluetooth or NFC. However, the emergent Smart TV model arises as an interesting alternative for the implementation of a new generation of public displays. This is due to its intrinsic connection capabilities with surrounding devices like smartphones or tablets. Nonetheless, the different approaches proposed by the most important vendors are still underdeveloped to support multiscreen and interaction capabilities for modern public displays, because most of them are intended for domestic environments. This research proposes multiscreen interactive middleware for public displays, which was developed from the principles of a loosely coupled interaction model, simplicity, stability, concurrency, low latency, and the usage of open standards and technologies. Moreover, a validation prototype is proposed in one of the most interesting public display scenarios: the advertising.

1. Introduction

Traditionally, public displays have played a role as static and nonpersonalized devices that broadcast information for many people indifferently. Nevertheless, modern approaches demand a new generation of public displays for pervasive environments, where they may be able to offer not only customized content but also interaction capabilities for users. Although several alternatives have been studied to make public displays smarter, one emerging model looks like the most interesting, the Smart TV initiative. Smart TV proposes a new generation of televisions and set top boxes with more processing power and a better Internet integration [1]. This emergent model also offers a valuable capability for connecting and sharing content with other devices like smartphones or tablets, via standards such as UPnP (Universal Plug and Play) or DLNA (Digital Living Network Alliance). This feature is extremely interesting for the new generation of public displays. In the past, several researches

have developed interaction schemes between public displays and mobile devices using personal area network technologies like Bluetooth or NFC (Near Field Communication). This kind of solutions has been designed thinking in a particular domain or application and they do not consider a multiscreen cooperation scheme where the content may be distributed between the screens in a complementary way. Therefore, research about a new generation of public displays based on a Smart TV model is still incipient.

In spite of the efforts of several important vendors such as Samsung, LG, Google, or Apple, a real open platform for enabling multiscreen interactive applications is still nascent. For the purpose of this research, the multiscreen concept makes reference to the collaboration between the screens of different devices [2]. The Smart TV screen is supported by mobile devices screens that not only display complementary content but also enable interactions. Most of the approaches for Smart TV and mobile devices interaction are based on nonstandard techniques over HTTP (Hypertext Transfer

Protocol) like long polling, which looks to overcome the restrictions associated with the stateless condition of the HTTP protocol. This implementation demands more bandwidth and increases the protocol overhead that is problematic for public display environments. Additionally, the architectures are designed thinking on domestic environments that support applications with few clients at home. A Smart TV-Smartphone multiscreen interactive solution for public displays settings demands a scalable architecture and a robust message transport mechanism.

The proposed solution enables a multiscreen interactive middleware for public displays based on a Smart TV-Smartphone cooperation model. This approach includes a reference architecture to implement the middleware, and it defines an interaction model based on the publish/subscribe paradigm. Middleware features are analyzed from important requirements for public display environments such as scalability, low latency, simplicity, concurrency, the use of open technologies, and a loosely coupled interaction model. We provided a reference implementation for the Android platform and it was validated in the advertising field, specifically in digital signage environments where public displays are required.

The paper is structured as follows. Section 2 summarizes some related works in the last years. Section 3 presents an architectural approach for the middleware. The next section summarizes some aspects related with the middleware communication model. Section 5 describes the experimental framework for validation and evaluation purposes. Section 6 discusses the experimentation results. The last section introduces some conclusions.

2. State of Art

The new generation of public displays has inspired several research works with different perspectives in the last years. However, they share a strong common motivation: a better experience from the user interaction perspective [3]. Specifically, this scholar focuses on the interaction with public displays using personal devices like smartphones or tablets. This section introduces some researches related to the interaction mechanisms for public displays, highlighting major interaction requirements for the Smart TV model. Then, we describe some existing middleware and toolkits for public displays and finally we analyze some toolkits and Smart TV approaches.

2.1. Public Displays Interaction Mechanisms. For years, several approaches have been studied about content adaptation and interaction schemes between public displays and smartphones. For example, [4] analyzes the interaction throughout gestures during a screen replication and [5] introduces a touch screen interaction supported on NFC capabilities. However, both approaches do not consider a real collaborative interaction between the devices and a screen replication approach is preferred instead. Other researches consider some interaction models for including zoom functions for the main public display content in the mobile devices [6, 7], as long as others consider some phone sensor functionalities

[8, 9]. Nonetheless, none of the previous approaches proposes a real collaborative multiscreen scheme between public displays and mobile devices; these solutions are addressed to specific applications or functions, which do not include a more generic middleware platform support that may be applied to several domains.

Although the mobile devices provide an obvious mechanism through which viewers can express their preferences and communicate them to the nearby public displays, the possible interaction mechanisms may be diverse. According to [10] these interaction techniques can be grouped into two major approaches.

The first group uses a custom application designed for the specificities of a particular displays system in a well-defined scenario; this dependence makes these applications useless for any other domain. Some researches of the University of Oulu in Finland [11], Lancaster University in England [12], University of Stuttgart in Germany [13], and University of Ottawa in Canada [14] are some examples of this first group. As an important contribution, these authors define several design requirements for a public display system deployment, but these experiments neither consider the use of Smart TV as an Interactive Public Display nor interaction schemes throughout smartphones that enable multiscreen features.

On the other hand, the second group approaches depend on the availability of several communication alternatives in the mobile devices such as Bluetooth, NFC, or IVR (Interactive Voice Response). Research works presented in [15–19] or [20] are examples for this second group. This form of interaction is very attractive to support an interaction almost universal. However, [10] remarks that these approaches “*may be limited in their ability to frame the interaction with regard to personalization and the shared meaning of the interaction.*” In this sense, a Smart TV-Smartphone cooperation scheme may be an interesting research alternative to implement robust multiscreen interaction schemes.

2.2. Public Displays Middleware and Toolkits. There are some related works on middleware systems which provide different levels of abstraction for communication complexities and different interaction modes for public displays like MAGIC Broker [21], OSGi Broker [22], or UbiBroker [23].

The MAGIC Broker provides a set of common abstractions and a RESTful Web services based protocol to develop interactive public large screen display applications using mobile device interactions. For this purpose, the RESTBroker uses a set of common abstractions such as channels, events, states, services, and content; specifically, the channels describe entities in the environment and they support a hierarchical structure. The events and state information are routed based on the channels, something similar to a topic in the publish-subscribe pattern implemented over HTTP. Otherwise, OSGi Broker is an evolution of MAGIC Broker, which replaces the RESTBroker to add support for SMS (Short Message Service) and VoiceXML (Voice eXtensible Markup Language) inputs. Both RESTBroker and OSGiBroker use the notion of channels following a publish-subscribe design pattern to decouple message sources from message sinks.

On the other hand, the UbiBroker is an event-based communication architecture for a pervasive display network. It is based on a proven and widely used general purpose open source publish-subscribe messaging software; also, it addresses several major requirements for pervasive display networks including decoupling, stability, simplicity, and interoperability. Regarding mobile devices interaction, UbiBroker supports several devices throughout hotspots user interfaces implemented using a Web paradigm. However, a real implementation for the Smart TV model is not obvious.

According to the previous analysis, it is important to remark that the current research looks for enabling more attractive ways of interaction with public displays, using the gestures commonly implemented in the mobile operating systems. According to our experience, a native application implementation supports more fluent and stable interactions in a real public display scenario than a Web implementation as UbiBroker suggests.

2.3. Smart TV Toolkits and Platforms. Smart TV model exposes interesting features to extend the interaction capabilities of conventional public displays, thanks to its ability to connect other devices like smartphones or tablets. Platforms like Samsung Convergence Framework [24] or Samsung MultiScreen SDK [25] have been the first steps to build Smartphone-Smart TV interaction schemes. The first one defines a proprietary model for the connection of Smart TV and smartphones based on RESTfull endpoints in a HTTP long polling communication model under a Local Area Network environment; the second one defines a proprietary SDK for the connection of Smart TV and Smartphone based on cloud services using WebSockets communication model [26]. Our previous work deploying a Smart TV-Smartphone cooperation model in digital signage reveals that Samsung Smart TV Convergence Framework has some restrictions related to the maximum number of concurrent connected users and some intermittent behavior during paring and connection process [27]. Moreover, the use of proprietary platforms restricts the adaptability of the system.

Other alternatives are related with box TV platforms like Google TV and Apple TV; the first one provides the Android platform ecosystem support for the development of third party applications, but the second one is still closed to third party developers.

A deeper analysis of the previous approaches reveals a common issue between them. Most of the interaction has been designed thinking in the mobile device as an input device and the Smart TV as an output device, which restricts the operation of a real multiscreen cooperation scheme. On the other hand, the use of techniques as HTTP long polling in the communication strategy imposes restrictions in the stability and scalability of a system supporting multiple users on public displays interaction environments.

This research proposes an open middleware to support multiscreen interaction schemes based on the Smart TV-Smartphone model capabilities. It looks to overcome the current restrictions in order to support the public displays environments requirements.

3. Middleware Architecture

In this section, we will describe the proposed architecture for the middleware. At first, we introduce some specific requirements for a middleware supporting public display environments; they were defined according to our experience during the research and the contribution of previous related works.

3.1. Requirements

3.1.1. Loosely Coupled Communication Model. In a typical public display-mobile device interactive system, users trigger actions by sending commands through their smartphones to get an answer from the public display. It demands a highly dynamic environment with support for ad hoc communications between the related nodes, to avoid complex setup hard-coupled interfaces. According to previous works [21, 23, 28, 29], an event-based communication model supporting a publish/subscribe interaction scheme may be the best alternative to meet these requirements.

3.1.2. Stability. The middleware has to provide a reasonable availability and a small number of crashes. Moreover, [23] remarks “It is challenging to achieve stability if communication middleware is built from scratch, as reliability tends to come over time after careful testing and sustained development support,” so it is advised to use proven and well tested communication solutions as starting point.

3.1.3. Open. One of the most important considerations during the middleware development was the ability to evolve supporting standard and open technologies. The use of standard open protocols, open source implementations, and open development platforms also eases the integration of third party applications.

3.1.4. Simplicity. The middleware should be designed thinking about third party developers, so the simplicity is a key requirement for them. Simplicity involves a well-defined API using software design patterns that enable its use and extension by third party apps.

3.1.5. Concurrent Interaction. Middleware should support multiple concurrent interactions from different users in front of the same public display. The number of supported users should be limited by the public screen size.

3.1.6. Low Latency Communication. The current mobile devices have a fluent and fast answer to user interactions most of the time. It is important to keep these features as long as the user is interacting with the public display from his smartphone/tablet in order to improve the user experience.

3.2. Architecture. Figure 1 shows the reference architecture for the middleware. The proposed architecture has a layered structure that decouples its main components functions; it also eases the middleware maintenance and its evolution over the time. At the bottom, this layered architecture is

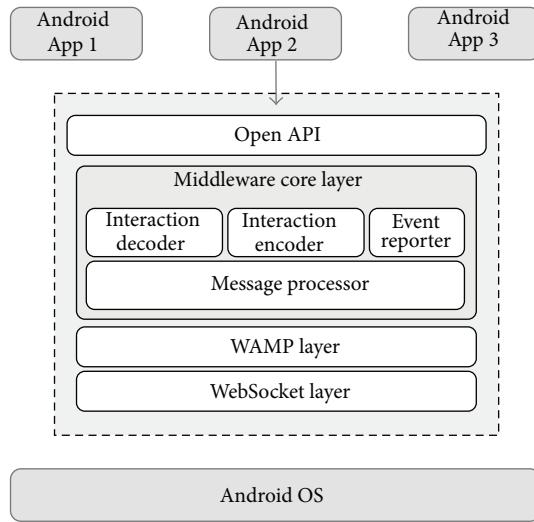


FIGURE 1: Middleware architecture.

supported by the Android OS capabilities, mainly by a rich set of networking features; the upper layer offers an Open API that allows the access to the middleware functions by third party apps in a simple manner, abstracting the underlying complex functions. Next, a brief description of each layer will be introduced starting at the bottom layer.

3.2.1. WebSocket Layer. A lightweight WebSocket protocol version was implemented to get a full real-time bidirectional communication between mobile devices and public displays [26]. Currently, several attempts to provide real-time communication using Internet Protocols rely on nonstandard techniques over a stateless protocol like HTTP; these techniques are known as Comet [30]. Polling, long polling, or streaming are some of the most popular HTTP Comet mechanisms, which postpone the HTTP response until the server has something to send to the client, simulating a real-time communication [31]. Nonetheless, the Comet techniques increase the latency and the protocol overhead, which restrict their application in the development of a middleware for user interaction purposes. The WebSocket protocol, instead, provides a full-duplex, bidirectional communication channel that operates through a single open socket over the Web, a desirable feature to build scalable real-time applications [32]. By reducing the overhead, the WebSocket Layer provides an efficient bidirectional communication channel between different devices with a low latency, one of the most important requirements for real-time user interaction systems [30, 31].

3.2.2. WAMP Layer. The proposed middleware can be defined as a message-oriented middleware (MOM) using a publish/subscribe interaction paradigm. MOM is a specific class of middleware that supports the exchange of general-purpose messages in a distributed application environment. The most sophisticated MOM systems ensure message delivery by using reliable queues and providing directory, security, and administrative services required to support messaging.

Publish/subscribe is a popular interaction paradigm where the sender is called the publisher and the receiver is called the subscriber. One publisher can publish a message to many consumers through a virtual channel called a topic. Consumers choose a topic of their interest to subscribe to it; any message for a specific topic is delivered to all the subscribers [33].

According to the previous description, this layer handles all the complexities related to the message interchange using a publish/subscribe interaction scheme. An open source Android implementation for Web Application Message Protocol (WAMP) was modified to assure stability and availability [34]. The high level WAMP protocol is supported by the WebSocket protocol, which makes the information exchange between publisher and subscribers truly asynchronous. Moreover, the notifications of events for subscribers are more efficient thanks to the overhead reduction. Therefore, the WAMP Layer provides a good efficiency/speed relationship, an important requirement to send information at proper times when the interaction between mobile devices and Smart TV public displays takes place.

3.2.3. Middleware Core Layer. The integration of several technologies and software design patterns may help to get the middleware expected behavior. Middleware Core Layer acts like a gateway for the messages exchange and it manages the interaction process according to a well-defined communication model. Users touch screen actions are preprocessed and then prepared as formatted messages that are sent to the other devices. Likewise, incoming messages are processed and delivered to third party Smart TV applications throughout the Open API.

The Middleware Core Layer functions rely on particular and more specialized components as follows.

- (i) *Interaction Encoder.* All touch events on the Smartphone screen need to be properly encoded and prepared prior to publishing them on the public display. Mobile applications sense the device screen and detect touch events and gestures, which triggers system touch events such as press, long press, tap, double tap, swipe, drag, move, or even a custom touch event.
- (ii) *Message Processor.* This component is responsible for sending and receiving messages to and from other devices throughout the WAMP Broker. Encoded touch events can be sent to the WAMP Broker by publishing messages with encoded information about a specific topic. The WAMP Broker defines the final destination for those messages throughout different notifications to the subscribers of that topic. Then, it reads the incoming messages and delivers the content to the interaction decoder.
- (iii) *Interaction Decoder.* All incoming encoded information needs to be properly decoded in order to rebuild the original touch event. These rebuilt touch events are sent to the mobile application using the Open API callback methods.

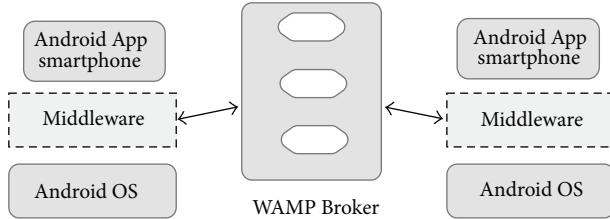


FIGURE 2: Pub/Sub communication model.

(iv) *Event Reporter*. A middleware activity log is possible thanks to the storage of execution and interaction data, collected throughout Flurry Analytics API [35]. Execution data have information about how often an application was used and it may be useful for crash reporting purposes to third party developers. On the other hand, interaction data deliver information about how many users interacted with the system and the way they did it. This information may be an indicator to measure the success of an application or advertising campaign, for example.

3.2.4. Open API. It is the main entry point for third party mobile/public display applications; the Open API abstracts the middleware capabilities and low-level communications protocol handling to the developers. A set of development patterns were implemented, so the application developer can use *factories* for clients and message creation, *observers* for connection, events, control and feedback notifications, and *singletons* for user interaction detection [36]. During the API development process the support for additional UI components other than the Android widget toolkit was not considered; the API development process was focused on the abstraction of the communication complexities. It keeps the API light and simple, one of the requirements described at the beginning of this section. The next section includes a more detailed description about the Open API functions.

4. Communication Model

Message-oriented middleware is increasingly adopted as an enabling technology for modern event-driven applications [37]. Publish-subscribe paradigm is frequently used on well-known software architectures and technology domains such as Enterprise Service Bus (ESB), Enterprise Application Integration (EAI), Service-Oriented Architecture (SOA), and Event-Driven Architecture (EDA) [38]. The proposed middleware architecture uses this approach to connect mobile devices and smart public displays in a scalable way (Figure 2).

The publish/subscribe paradigm, as used in MOM systems, enables the devices to subscribe to topics of interest. Publish/subscribe MOM relies on asynchronous communications and it enables data-centric communications; according to this model, the consumers subscribe to the information they are interested in, and the publishers make these data available [39]. Typically, the publisher publishes messages to a broker on well-known topics, and the subscriber subscribes

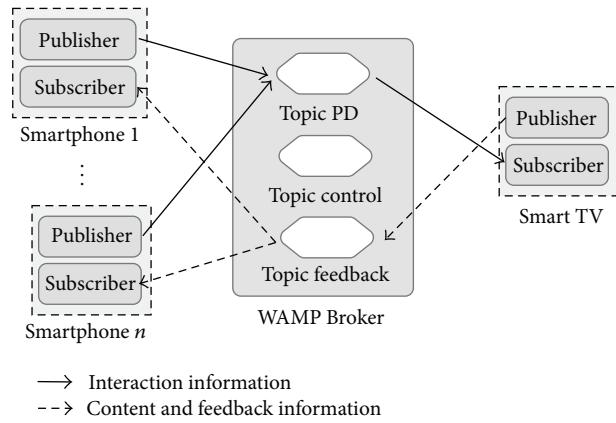


FIGURE 3: Interaction, content, and feedback information exchange.

to these topics. On the other hand, the broker also assures the message delivery, so a message is not erased until all subscribers to a specific topic have received the data from the broker; it makes the communication model lighter for the clients. This is an important requirement for a Smart TV-Smartphone multiscreen middleware for public display purposes, because simultaneous end-to-end connectivity with all subscribers is not always guaranteed.

4.1. Interaction Model. In a Smartphone-Smart TV environment for public displays, one of the most important tasks is the ability to send information about the user touch screen interaction in the mobile device to the public display. So, the mobile device must publish appropriate messages on a specific topic in the WAMP Broker. At the same time, the Smart TV must subscribe to that topic to receive messages from all connected clients (Figure 3).

In this kind of environments, the Smart public display needs to know more details about the connected mobile devices. For example: How many of them are connected? When a new Smartphone is ready to publish messages for a specific Smart TV topic? Or when a Smartphone disconnection has taken place? The proposed interaction model provides a mechanism to handle these issues using a special topic where Smartphone and Smart TV can share special control messages (Figure 4). Throughout this special topic, application developers can implement sophisticated controls structures when required.

Otherwise, there are also some scenarios where Smart TV needs to share content and information to a particular device or group of devices. As in the previous case, the middleware uses a special topic where all devices can exchange supplementary information not related with interaction or control messages (Figure 3). For example, this special topic may transport the movie short description in a public display showing a movie list, improving the user comprehension of the content [40].

4.2. Protocol Description. Proposed middleware uses a well-defined protocol to enable the message interchange according

TABLE 1: Message details.

Message		
Field	Type	Description
Uuid	String	Message source identifier
Type	Enum: MessageType	Enumeration with values: Move, Press, Long Press, Tap, Double Tap, Swipe, Drag, Custom, Setup, Ping, Bye, and Feedback
StartContent	String	Payload field for arbitrary data or serialized motion events
EndContent	String	Payload field for arbitrary data or serialized motion events
Extras	String	Payload field for extra data or binary encoded content

TABLE 2: Motion event details.

Motion event		
Field	Type	Description
Id	Integer	Message source identifier
Action	Enum: MessageAction	Enumeration values: Action Down, Action Up, Action Move, Action Cancel, Init, and End
x	Integer	X coordinate of motion event relative to the screen layout
y	Integer	Y coordinate of motion event relative to the screen layout
EventTime	Long	Motion event duration in milliseconds
DownTime	Long	First time for user pressed down event, which starts a stream of new events
Source	Integer	Source as specified by the O.S

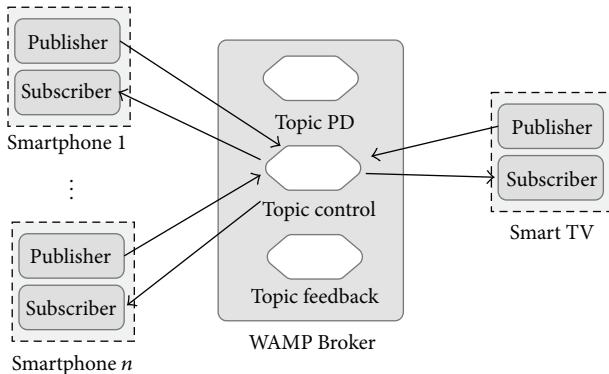


FIGURE 4: Control information exchange.

to publish/subscribe paradigm. Table 1 shows the structure for a generic frame and Table 2 shows the structure for message transporting touch events information.

Complex touch screen gestures like a swipe or drag over the screen are composed by several motion events, which are encapsulated throughout MotionEvent objects; however, only two of these objects are required to store the whole information. To publish a message with a MotionEvent object, it must be serialized and formatted using JSON format; with this structure, serialized data can be encapsulated into the message using the startContent, endContent, or Extras fields. Furthermore, convenience messages were defined for the most common user interaction actions. Being Android, the ground platform for the middleware reference implementation, there is a correspondence between Android touch gestures and convenience messages. As an example, Table 3 shows some convenience messages for Tap and Swipe gestures; however, a full set of messages support other gestures like Move, Press, Long Press, and Double Tap.

4.3. API Description. A small set of classes and interfaces were designed to make the communication management easier for third party developers.

Figure 5 shows a class diagram for the API. Next, a brief description of the API main classes will be presented.

- (i) *Client*. Middleware main class to set up a connection with WAMP Broker: it also enables the publishing and subscribing process to different topics. Furthermore, this class supports the information pickup for log purposes.
- (ii) *ClientFactory*. Factory pattern implementation for *Client* objects creation, according to specific Handlers and parameters.
- (iii) *ConnectionHandler*. This interface defines callback methods for handling notifications about connection events to the WAMP Broker.
- (iv) *EventHandler*. This interface defines callback methods for handling notifications about the user interaction over the touch screen.
- (v) *ControlHandler*. This interface defines callback methods for handling notifications about control events from publishers and subscribers.
- (vi) *FeedbackHandler*. This interface defines callback methods for handling notifications about events published in the feedback topic.
- (vii) *Message*. This class encapsulates the content structure for the whole messages interchanged between the clients (publishers/subscribers) and the WAMP Broker. Each message has a type, which is defined in the Enumeration MessageType, a source id, a payload that may be a serialized MotionEvent object and extra data.

TABLE 3: Protocol messages details.

	Protocol
Message	Structure
Tap	<pre>{ "uuid": "49f319b2-9689-44bf-b9fd-a2b076c18c9b", "type": "TAP", "startContent": { "action": "ACTION_DOWN", "downTime": 39504973, "eventTime": 39504973, "id": 3, "source": 4098, "x": 373.4812999999998, "y": 513.59875 }, "endContent": null, "extras": null, } { "uuid": "49f319b2-9689-44bf-b9fd-a2b076c18c9b", "type": "DOUBLE_TAP", "startContent": { "action": "ACTION_DOWN", "downTime": 40929359, "eventTime": 40929724, "id": 3, "source": 4098, "x": 114.84050000000001, "y": 1036.1904 }, "endContent": { "action": "ACTION_UP", "downTime": 40929359, "eventTime": 40929359, "id": 3, "source": 4098, "x": 292.59363000000002, "y": 646.49492999999995 }, "extras": null, } }</pre>
Swipe	<pre>{ "uuid": "49f319b2-9689-44bf-b9fd-a2b076c18c9b", "type": "SWIPE", "startContent": { "action": "ACTION_DOWN", "downTime": 40929359, "eventTime": 40929359, "id": 3, "source": 4098, "x": 292.59363000000002, "y": 646.49492999999995 }, "endContent": { "action": "ACTION_UP", "downTime": 40929359, "eventTime": 40929359, "id": 3, "source": 4098, "x": 292.59363000000002, "y": 646.49492999999995 }, "extras": null, } }</pre>

(viii) *MessageFactory*. Factory pattern implementation for *Message* objects creation, according to specific parameters: it defines convenience methods for objects creation according to the type of touch event generated from the user interaction.

According to the previous description, the setup for message interchange between smartphones and Smart TV using the API is so simple: a peer only needs to get a client instance from the ClientFactory and then publish or subscribe to the desired topic.

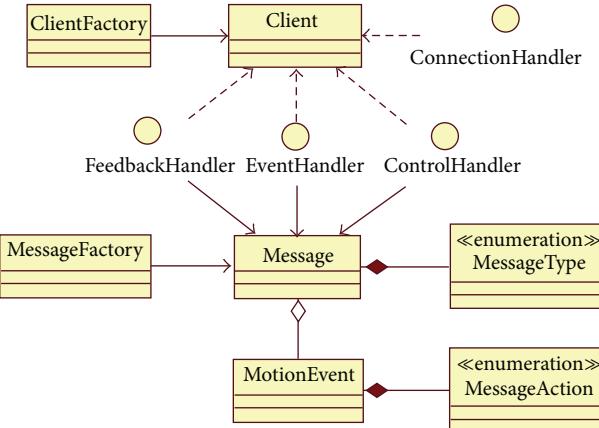


FIGURE 5: API class diagram.

5. Experimental Framework

5.1. *Motivation Stage and Prototype Description*. One of the most interesting scenarios for public displays is related with advertising. Although several researches have focused on better mechanisms for ads delivery on personal devices like mobile phones, the ads delivery in public spaces, including malls or streets, is so attractive. This trend, known as digital signage is still very important for advertisers taking into account that the 75% of the purchase decisions take place in the shopping places or close to them [41]; specifically, these are the preferred places to locate public displays. On the other hand, the advertising campaigns may evolve from mainly static to more engaging experiences, if the users interaction with the public displays is improved beyond an attractive looking and feel to watch the ads in the screen; it is something valuable for advertisers with persuasion purposes. In this sense, the proposed middleware is a great support for these high interaction environments.

With this motivation in mind, a little prototype for experimentation purposes was developed and tested in an academic environment. The prototype basis was to implement an electronic alternative to a traditional static ads board, in which people post ads using paper posters; these boards are frequently found on small shops or academic campus. The proposed implementation replaces the old board by a new cooperative Smart TV-Smartphone model, where both devices screens are offering ads to users under different but complementary approaches: ads recommendations for group profiles on public TV screen and ads recommendations for individual profiles on the smartphones screens. Moreover, the interaction capabilities between both devices change the static behavior of the traditional board; the basic architecture for the prototype is shown in Figure 6.

In summary, Android applications were developed for mobile phones and Google Smart TV set top box. These applications used the middleware API for interaction management and the users in front of the public display login to the system using a “Login with Facebook feature.”

Briefly, some of the main functionalities of the implemented prototype were as follows.

TABLE 4: Offline tests hardware setup.

	Hardware		
	Smartphone	Smart TV	WAMP Broker
Type	Mobile	Google TV	Laptop
CPU	Qualcomm Snapdragon 400 1.2 GHz	Intel Atom CE4150 1.2 GHz	2.5 GHz
RAM	1 GB	8 GB	8 GB
OS	Android 4.4	Android 3.2	MAC OS X
Network	Wi-Fi 802.11 a/b/n	Wi-Fi 802.11 a/b/n	Ethernet

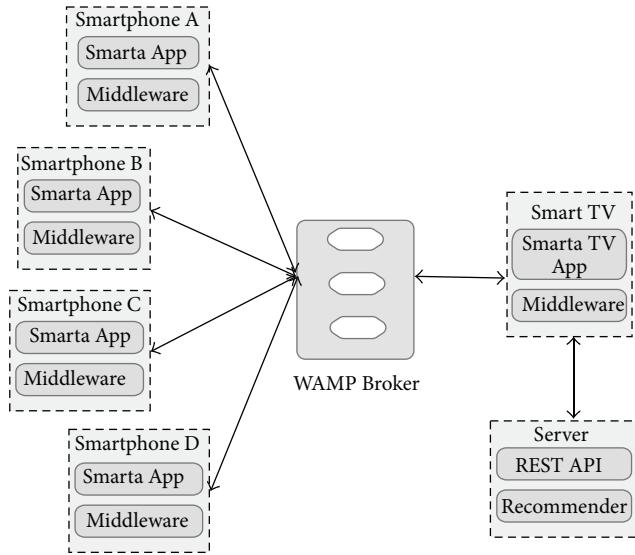


FIGURE 6: Prototype architecture.

(i) *Ads Recommendations for a Group of Users Watching the TV Screen.* The groups of users were limited to four people, basically for usability reasons taking into account the screen size (42 inches). The recommender calculates the best ads list for the people interacting with the public screen; these ads were organized on list of six ads each (see Figure 7); the recommender implementation is out of the scope of this paper.

(ii) *Ads Recommendations according to Individual Preferences on the Smartphone Screen.* The recommender calculates the best ads list for each person in front of the public display and it shows them on the mobile device screen (see Figure 8). The user can get detailed information for a particular advertisement and add ads to Favorites.

(iii) *Basic Interaction between Mobile Device Application and Public Display.* The user can go over the ads on the public display using a control pad from the mobile application (Figure 9); using a tap gesture the user can get detailed information for a particular ad in public display and watch it on the mobile device screen. Each user is identified by a specific color (Figure 7).

(iv) *Rating Ads.* User can rate the ads on public screen or mobile device list using “Like” and “No Like” options available in the mobile application user interface. For public display, each user is identified by a specific color (Figure 7).

(v) *Posting Ads.* Users post ads to the public screen, writing the ad information from their mobile device. The user can use the smartphone camera or its photo gallery to upload a product picture (Figure 9).

(vi) *Interaction Logs.* Thanks to the middleware capabilities, both applications are enabled to store interaction activity logs for each user action. For example, in this scenario the logs information was useful to generate implicit ratings according to the user action (request more info about an ad, ignore ads from the screen, add the ad to favorites, etc.).

5.2. Evaluation Methodology. Frequently, performance related aspects are the most common evaluation parameters for a message-oriented middleware (MOM). So, the system should be tested in almost-real scenarios and also in extreme conditions [42, 43] to find out reliable information about its performance. According to the previous arguments, online and offline tests were performed in two phases to observe the system behavior.

5.2.1. Offline Experimentation. During this phase, simulated components generated high traffic conditions to the middleware. Figure 10 shows the basic architecture for the testing scenario. During these tests, different hardware devices sent and received messages at different rates with different computational load. Table 4 summarizes the hardware features setup for this phase.

5.2.2. Online Experimentation. During this phase, real users participated in the advertising scenario described in the previous section. As long as the offline tests are focused on the system performance under extreme conditions, the online tests try to simulate a real public display scenario for the middleware operation. As the middleware interaction protocol is based on gestures information sent from mobile devices, these tests enable the evaluation of the middleware performance when real users send real gestures using the API from the Android applications; this feature was not evaluated during the offline tests. For this purpose, twenty-four (24) students, eight (8) women and sixteen (16) men from

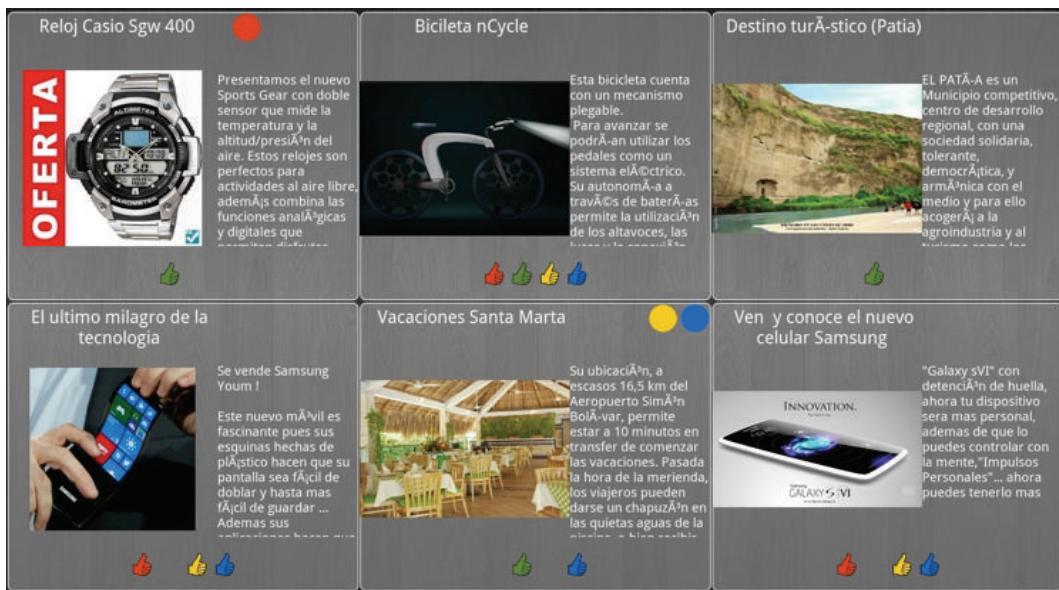


FIGURE 7: Public display ads screen.

FIGURE 8: Mobile device adds list screen.

the Electronics and Telecommunications Engineering program from the University of Cauca, with ages between 20 and 25 years participated in the experiment. Groups of 4 people were set up randomly to interact with the system during at least five (5) minutes periods.

The specific tests description and the results will be described in the next section.

6. Discussion

Next, we will analyze the most relevant results according to the evaluation methodology proposed in the previous section.

6.1. Offline Tests

6.1.1. Test Number 1 Maximum Sustainable Throughput. The purpose of the first test is to find the Maximum Sustainable Throughput (MST). A single subscriber and a single publisher were configured during the test. The publisher was sending messages with 64-byte length at a rate below 1500 messages per second (mps). Moreover, the receiver rate was almost the same as the publisher-sending rate. When the publisher sending rate was increased beyond 1500 mps, the receiver keeps the receiving rate around the 1500 mps; the sender increased the sending rate up to 2000 mps. Figure 11 summarizes the system behavior at different sending rates. According



FIGURE 9: User pad control and ads post.

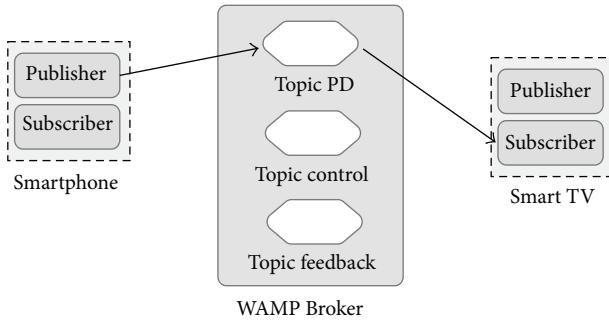


FIGURE 10: Offline test architecture.

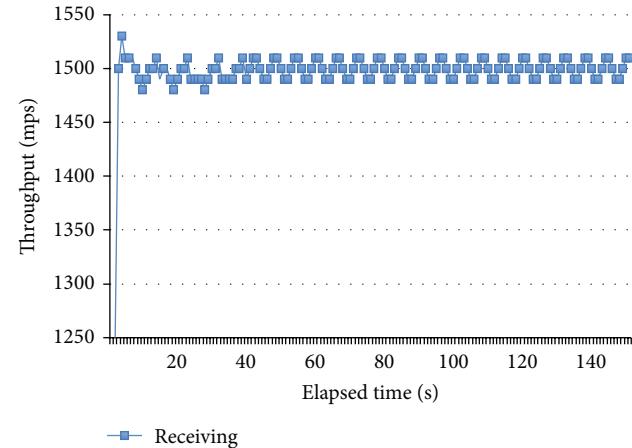


FIGURE 12: Subscriber receiving rate at MST.

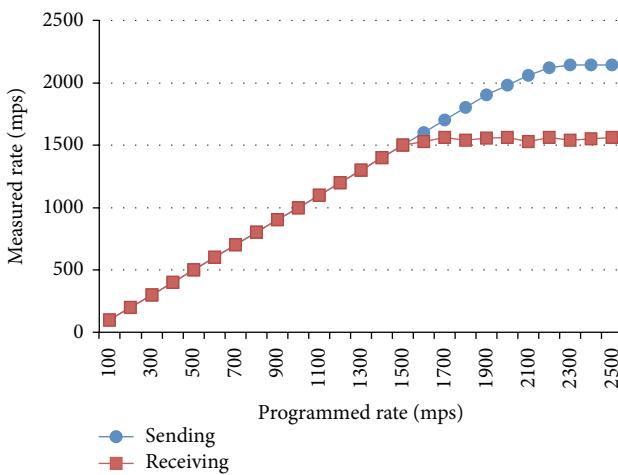


FIGURE 11: Sender and receiver rates comparison.

to the graph, the MST for the middleware is 1500 mps (with hardware support features described on Table 4).

6.1.2. Test Number 2 Effective Rate at MST. Once the MST has been calculated, the second test was executed in similar conditions to the first test but this time the publisher-sending rate remained constant in 1500 mps to observe the subscriber receiving rate at different points in the time. The results in Figure 12 show the system stability to the MST throughput.

6.1.3. Test Number 3 CPU Consumption at MST. Some measurements about CPU consumption were performed over the hardware components (Smart TV, Smartphone, and Broker) in different points over the time working at MST (1500 mps). Figure 13 shows a CPU high consumption in all devices during the first five (5) seconds of the test; it is due to the connection process and the setup of the networking threads. However, ten (10) seconds later the behavior starts to be stable. On the other hand, it is possible to observe a higher CPU consumption for the Smart TV; it is due to a faster microprocessor available in the Smartphone.

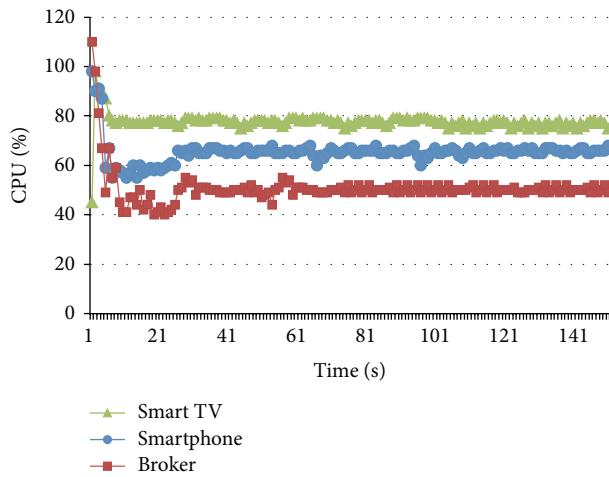


FIGURE 13: CPU consumption at MST.

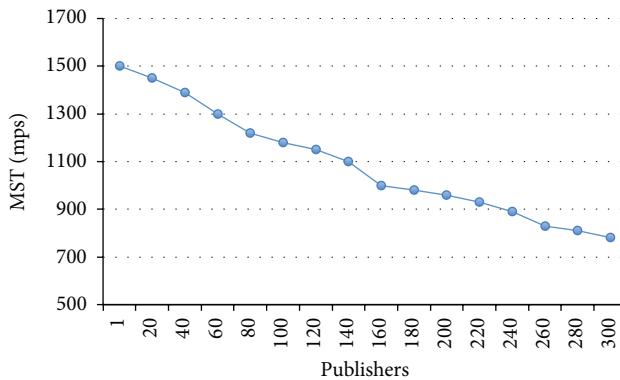


FIGURE 14: MST versus number of publishers.

6.1.4. Test Number 4 MST with a Different Number of Publishers. This test observes the behavior of the MST when the number of publishers increases. So, one subscriber and 64 bytes length messages were configured during the test. The results are summarized on Figure 14. As expected, the number of publishers affects the MST adversely; with one publisher, the MST keeps the 1500 mps rate as in Test number 1, but it descends to 780 mps when 300 publishers are sending messages at a 10 mps rate. Anyway, it may be an extreme rate for most of the real public display scenarios.

6.1.5. Test Number 5 MST with a Different Number of Subscribers. This test observes the behavior of the MST when the number of subscribers increases. One publisher and 64 bytes length messages were configured during the test. The results are summarized on Figure 15. Like the previous test, the number of publishers affects the MST adversely; in this case, the MST descends to 1350 mps when 300 subscribers send messages at a 10 mps rate. However, the impact is lower because most of the work is performed in the broker.

6.1.6. Test Number 6 MST with Different Message Lengths. This test observes the behavior of the MST when the message

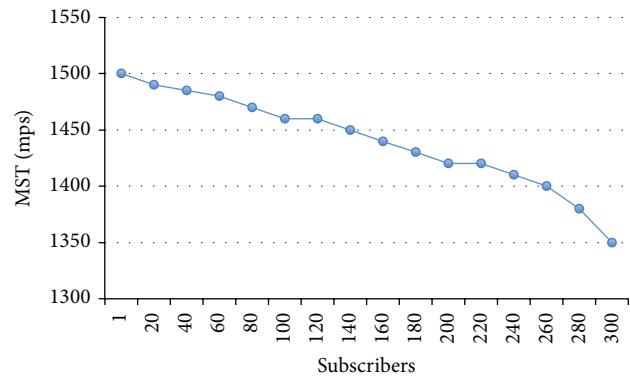


FIGURE 15: MST versus number of subscribers.

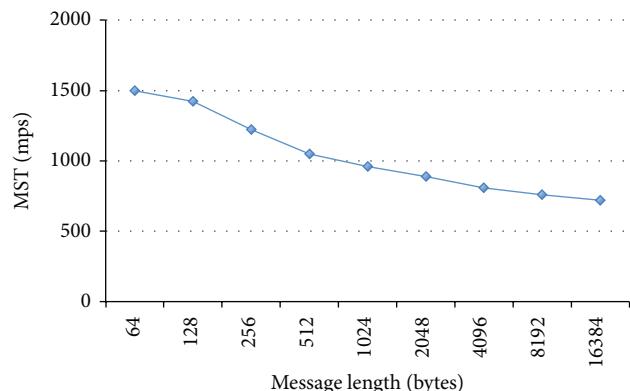


FIGURE 16: MST versus message length.

TABLE 5: Latency and connection time.

	System metrics	Average (ms)	Standard deviation
Connection time		26.56	7.61
Latency		40.24	9.15

length changes. One publisher and one subscriber were involved, changing the message length and calculating the MST for each case. In Figure 16 it is possible to observe how the MST decreases as long as the message length increases, because longer messages require more bandwidth and also more computational resources.

6.1.7. Test Number 7 Connection Time and Latency. This test evaluates the connection times and the latency. The first one is defined as the time between the WebSocket open request from the client and the WAMP Broker answer. Otherwise, the latency measures the time between a message posted by the publisher and the message reception by the subscriber. One subscriber and one publisher were configured sending 64 bytes length messages. The results over 1000 samples are summarized in Table 5.

6.2. Online Tests. According to the previous description, the offline tests were focused on the overall system performance

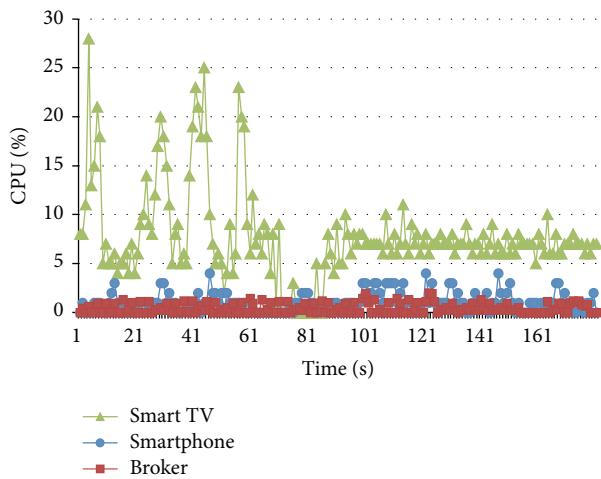


FIGURE 17: Online test CPU consumption.

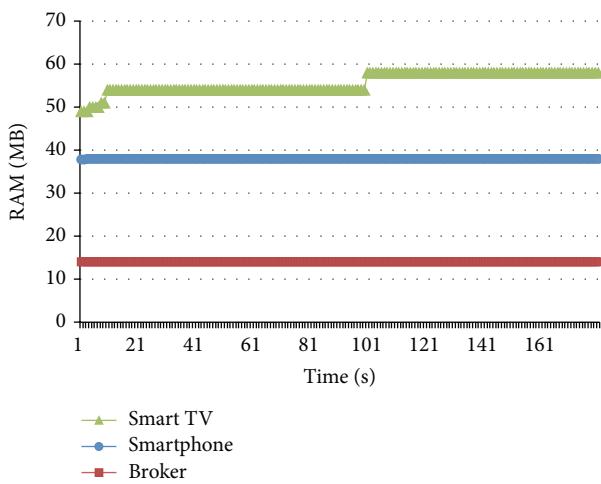


FIGURE 18: Online test RAM consumption.

under extreme conditions. The online tests were applied in a real and common scenario in a public display environment, with four (4) users in front of the screen interacting with the electronic ads board prototype described in Section 5. The number of users was restricted according to the screen size (42 inches) to assure a better experience for the volunteers during the experiment. Therefore, four publishers (4 smartphones) and one subscriber (the Smart TV) were used during the test to measure the CPU and RAM consumption for each component during five (5) minutes observation periods, according to the methodology described in the previous section. Figures 17 and 18 show a low CPU/RAM consumption and a rather stable behavior; it is interesting to observe the four high peaks, which take place when each user is requesting a new connection and a new set of group recommendations is calculated. In summary, the online tests show a good middleware components performance with low computational resources consumption, suggesting a good behavior on most of the real public display scenarios.

7. Conclusion

This research proposes an interactive Smart TV-Smartphone multiscreen middleware for public displays. Previous implementations for enabling public displays-smartphones interaction frequently were domain or technology specific. On the other hand, previous efforts by some vendors about the rising Smart TV model have implemented solutions based on HTTP techniques like long polling, which compromises the stability and the scalability of an interactive middleware for public display purposes. The contributions of the proposed middleware may be analyzed from the requirements defined previously at the beginning of Section 3.

Based on previous findings, we design and implement a scalable message-oriented middleware following a publish/subscribe paradigm to get a *loosely coupled communication model*. Furthermore, the proposed middleware layered architecture eases the decoupling between the complexities related with the low-level communication protocols, the interaction model for messages interchange, and the business logic of each third party application for a specific domain. In the same way, we design an *Open* protocol based on standard technologies like WebSockets and JSON using open source implementations to support the Smart TV-Smartphone cooperation scheme.

The design of an open architecture for the middleware based on the publish/subscribe paradigm improves the *stability* of the connections over other alternatives based on non-standard HTTP techniques like long polling, an important requirement for public displays environments where multiple users must be supported. The proposed middleware had a stable behavior during all online and offline tests, compared with our previous work using the Samsung Convergence Framework [24, 27].

Otherwise, we design a *Simple API* over a widely supported platform like Android, which enables the use of most of the capabilities of the current mobile devices. Simple extensions would enable the use of hardware features (GPS, accelerometer, gyroscope, etc.) to motivate the development of creative and engaging applications. For example, accelerometer events may be used to simulate how objects are thrown to the public display; other modes may be created to engage the users in a competition using strength or speed gestures from the mobile phones. Therefore, this reference implementation enables the use of most of the set top boxes based on the Google platform.

About the *Concurrent Interaction*, the middleware uses a simple design based on gestures and messages interchange between the Smart TV and the mobile devices in a public display environment, which improves the scalability of the system. Although the prototype showed a good performance for four concurrent users, the offline tests evidence a good concurrent connections behavior still in extreme conditions.

Moreover, the middleware showed a *Low Latency* for the pool of connections during online and offline tests; it suggests the middleware applicability in several scenarios related to advertising, including home environments. A lot of possibilities are open to design creative multiscreen applications for entertainment purposes, including interactive multiscreen

games thanks to the almost real-time transport message support provided by the middleware. Other scenarios like E-learning may be also interesting; for example, multimedia sessions oriented by the teacher on a Smart TV may be followed with complementary content in students' mobile devices at the same time. We keep in mind that all of these possibilities can be effectively addressed with low latency features.

About the middleware application, although the Android platform was selected to build a reference implementation for the middleware, the proposed architecture may be replied to other platforms; a new generation of open Smart TV boxes could be built over platforms like Raspberry Pi; for example, something that may be attractive for emergent markets.

Regarding the middleware evaluation, the offline tests show a promising performance on extreme conditions with average hardware capabilities, as long as the online tests with real users show a very good performance in a nonintensive public display scenario for the advertising domain. More demanding public display scenarios may be implemented using larger screens with Smart TV boxes support, using better hardware resources; as a matter of fact, the architecture was designed to be extensible from domestic places to more demanding public display environments.

Finally, some middleware limitations are related to security issues; a security framework to protect the data privacy for the users is an interesting topic for future research. On the other hand, the current implementation has been addressed to ad hoc deployments at indoor spaces (e.g., shops or specific places in a mall); large deployments using public displays networks have been addressed by other researches and it may be an interesting extension for the current middleware implementation.

Conflict of Interests

The authors declare that there is no conflict of interests regarding the publication of this paper.

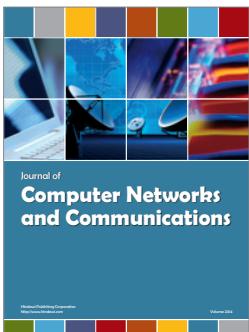
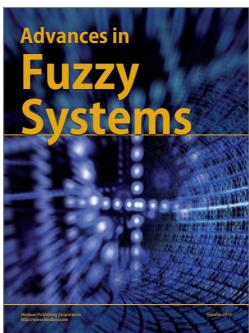
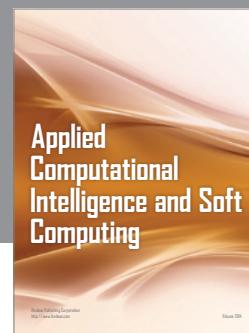
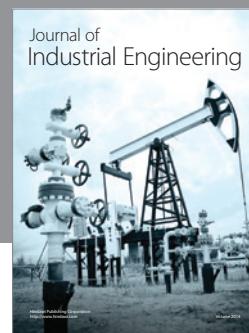
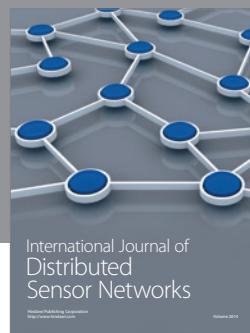
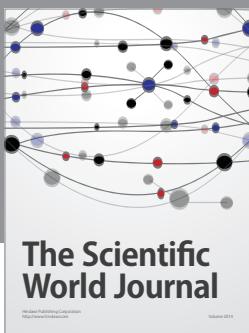
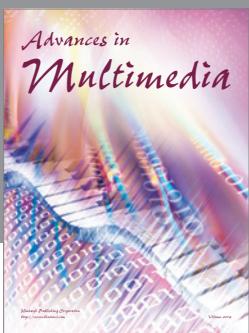
Acknowledgments

This work was supported by the University of Cauca through Projects VRI 3593 "SMARTA: Modelo para el Despliegue de Publicidad en Entornos de Computación Ubicua Soportado en un Esquema de Cooperación Smart TV-Smartphone" and VRI 4045 "MANTISS: Modelo para la Adaptación de Contenidos Publicitarios en Entornos n-Screen Interactivos Soportados en un Esquema de Colaboración Smart TV-Smartphone." Francisco Martínez is funded by Colciencias Doctoral Scholarship no. 567. Part of this work has been done at Universitat Pompeu Fabra, Barcelona, with partial support from the EEE project TIN2011-28308-C03-03, where Francisco Martínez-Pabón, Jaime Caicedo-Guerrero, and Jhon Jairo Ibarra-Samboni were visiting scholars in 2014.

References

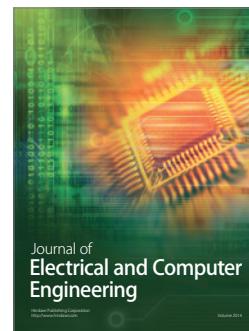
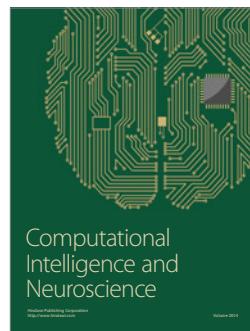
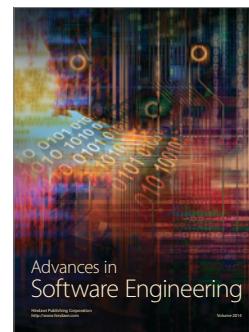
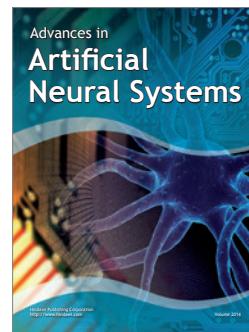
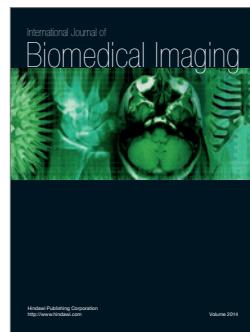
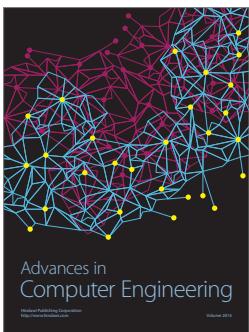
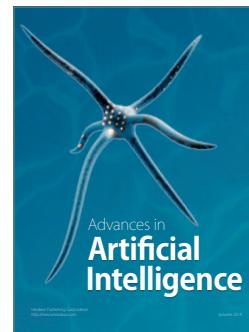
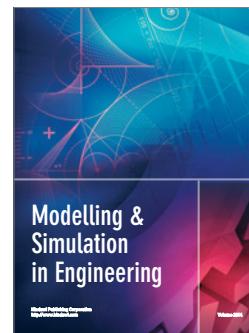
- [1] F. Jewett, "Why smart TV is the next big thing," *Mobile Connect*, vol. 1, no. 2, pp. 1–15, 2011.
- [2] C. Yoon, T. Um, and H. Lee, "Classification of N-screen services and its standardization," in *Proceedings of the 14th International Conference on Advanced Communication Technology (ICACT '12)*, pp. 597–602, February 2012.
- [3] C. Bauer, P. Dohmen, and C. Strauss, "Interactive digital signage—an innovative service and its future strategies," in *Proceedings of the International Conference on Emerging Intelligent Data and Web Technologies (EIDWT '11)*, pp. 137–142, Tirana, Albania, September 2011.
- [4] E. Protalinski, "Google Research's Open Project lets you beam apps to an external display using only your smartphone's camera," *The Next Web*, 2013, <http://thenextweb.com/google/2013/09/26/google-researchs-open-project-lets-you-beam-apps-to-an-external-display-using-only-your-smartphones-camera/>.
- [5] G. Broll, E. Vodicka, and S. Boring, "Exploring multi-user interactions with dynamic NFC-displays," *Pervasive and Mobile Computing*, vol. 9, no. 2, pp. 242–257, 2013.
- [6] P. Baudisch, N. Good, and P. Stewart, "Focus plus context screens: combining display technology with visualization techniques," in *Proceedings of the 14th Annual ACM Symposium on User Interface Software and Technology (UIST '01)*, pp. 31–40, November 2001.
- [7] S. Boring, M. Jurmu, and A. Butz, "Scroll, tilt or move it: using mobile phones to continuously control pointers on large public displays," in *Proceedings of the 21st Annual Conference of the Australian Computer-Human Interaction Special Interest Group: Design: Open Open 24/7 (OZCHI '09)*, pp. 161–168, New York, NY, USA, November 2009.
- [8] R. Ballagas, M. Rohs, and J. G. Sheridan, "Sweep and point and shoot: phonecam-based interactions for large public displays," in *Proceedings of the Extended Abstracts on Human Factors in Computing Systems (CHI EA '05)*, pp. 1200–1203, New York, NY, USA, 2005.
- [9] R. Hardy and E. Rukzio, "Touch & interact: touch-based interaction of mobile phones with displays," in *Proceedings of the 10th International Conference on Human-Computer Interaction with Mobile Devices and Services (MobileHCI '08)*, pp. 245–254, September 2008.
- [10] R. José, J. Cardoso, F. Alt, S. Clinch, and N. Davies, "Mobile applications for open display networks: common design considerations," in *Proceedings of the 2nd ACM International Symposium on Pervasive Displays (PerDis '13)*, pp. 97–102, New York, NY, USA, June 2013.
- [11] T. Ojala, V. Kostakos, H. Kukka et al., "Multipurpose interactive public displays in the wild: three years later," *Computer*, vol. 45, no. 5, Article ID 6174993, pp. 42–49, 2012.
- [12] N. Taylor and K. Cheverst, "Supporting community awareness with interactive displays," *Computer*, vol. 45, no. 5, pp. 26–32, 2012.
- [13] F. Alt, J. Müller, and A. Schmidt, "Advertising on public display networks," *Computer*, vol. 45, no. 5, pp. 50–56, 2012.
- [14] Q. Chen, F. Malric, Y. Zhang et al., "Interacting with digital signage using hand gestures," in *Image Analysis and Recognition*, M. Kamel and A. Campilho, Eds., pp. 347–358, Springer, Berlin, Germany, 2009.
- [15] R. José, N. Otero, S. Izadi, and R. Harper, "Instant places: using bluetooth for situated interaction in public displays," *IEEE Pervasive Computing*, vol. 7, no. 4, pp. 52–57, 2008.
- [16] P. Holleis, G. Broll, and S. Böhm, "Advertising with NFC," in *Proceedings of the Workshop on Pervasive Advertising and Shopping, in Conjunction with the 8th International Conference on Pervasive Computing (Pervasive '10)*, Helsinki, Finland, 2010.

- [17] R. Hardy, E. Rukzio, M. Wagner, and M. Paolucci, "Exploring expressive NFC-based mobile phone interaction with large dynamic displays," in *Proceedings of the 1st International Workshop on Near Field Communication (NFC '09)*, pp. 36–41, February 2009.
- [18] H. Hu, Y. Wen, H. Luan, T. Chua, and X. Li, "Toward multiscreen social TV with geolocation-aware social sense," *IEEE MultiMedia*, vol. 21, no. 3, pp. 10–19, 2014.
- [19] X. Li, T. Xie, and Y. Wen, "Multi-screen social TV over cloud-centric media platform," in *Proceedings of the 11th Annual International Conference on Mobile Systems, Applications, and Services (MobiSys '13)*, pp. 481–482, ACM, Taipei, Taiwan, June 2013.
- [20] H. Sato, M. Urata, K. Yoguchi, N. Arakawa, N. Kanamaru, and N. Uchida, "Linking digital signage with mobile phones," in *Proceedings of the 15th International Conference on Intelligence in Next Generation Networks (ICIN '11)*, pp. 86–91, 2011.
- [21] A. Erbad, M. Blackstock, A. Friday, R. Lea, and J. Al-Muhtadi, "MAGIC broker: a middleware toolkit for interactive public displays," in *Proceedings of the 6th Annual IEEE International Conference on Pervasive Computing and Communications (PerCom '08)*, pp. 509–514, Hong Kong, March 2008.
- [22] J. Ferreira, J. Leitão, and L. Rodrigues, "A-OSGi: a framework to support the construction of autonomic OSGi-based applications," in *Autonomic Computing and Communications Systems*, A. V. Vasilakos, R. Beraldí, R. Friedman, and M. Mamei, Eds., pp. 1–16, Springer, Berlin, Germany, 2010.
- [23] T. Heikkilä, P. Luojus, and T. Ojala, "UbiBroker: event-based communication architecture for pervasive display networks," in *Proceedings of the IEEE International Conference on Pervasive Computing and Communication Workshops (PERCOM Workshops '14)*, pp. 512–518, March 2014.
- [24] "Convergence App API—Samsung Smart TV Apps Developer Forum," Online, 2014, <http://www.samsungforum.com/Guide/ref00003/index.html>.
- [25] Samsung MultiScreen SDK, 2014, <http://multiscreen.samsung.com/>.
- [26] I. Fette and A. Melnikov, "The WebSocket Protocol," 2014, <https://tools.ietf.org/html/rfc6455>.
- [27] F. Martínez-Pabón, J. Caicedo-Guerrero, J. J. Ibarra-Samboni, G. Ramírez-González, M. Muñoz-Organero, and A. Chantre-Astaiza, "Smart TV—smartphone cooperation model on digital signage environments: an implementation approach," in *Proceedings of the 4th International Conference on Mobile Services, Resources, and Users (MOBILITY '14)*, pp. 25–31, 2014.
- [28] N. Kaviani, M. Finke, S. Fels, R. Lea, and H. Wang, "What goes where?: designing interactive large public display applications for mobile device interaction," in *Proceedings of the 1st International Conference on Internet Multimedia Computing and Service (ICIMCS '09)*, 2009, pp. 129–138.
- [29] M. Román, C. Hess, R. Cerqueira, A. Ranganathan, R. H. Campbell, and K. Nahrstedt, "Gaia: a middleware platform for active spaces," *ACM SIGMOBILE Mobile Computing and Communications Review*, vol. 6, no. 4, pp. 65–67, 2002.
- [30] D. Cameron, *A Software Engineer Learns HTML5, JavaScript and jQuery: A Guide to Standards-Based Web Applications*, Cisdal Publishing, 1st edition, 2013.
- [31] V. Pimentel and B. G. Nickerson, "Communicating and displaying real-time data with WebSocket," *IEEE Internet Computing*, vol. 16, no. 4, pp. 45–53, 2012.
- [32] V. Wang, F. Salim, and P. Moskovits, *The Definitive Guide to HTML5 WebSocket*, Apress, Berkeley, Calif, USA, 1st edition, 2013.
- [33] P. T. Eugster, P. A. Felber, R. Guerraoui, and A.-M. Kermarrec, "The many faces of publish/subscribe," *ACM Computing Surveys*, vol. 35, no. 2, pp. 114–131, 2003.
- [34] GitHub, "tavendo/WAMP," 2014, <https://github.com/tavendo/WAMP>.
- [35] Analytics | Flurry, 2014, <http://www.flurry.com/solutions/analytics>.
- [36] E. Gamma, R. Helm, R. Johnson, and J. Vlissides, *Design Patterns: Elements of Reusable Object-Oriented Software*, Addison-Wesley, Reading, Mass, USA, 1st edition, 1994.
- [37] J. A. Lundar, T.-M. Grønli, and G. Ghinea, "Performance evaluation of a modern web architecture," *International Journal of Information Technology and Web Engineering*, vol. 8, no. 1, pp. 36–50, 2013.
- [38] D. A. Chappell, *Enterprise Service Bus: Theory in Practice*, O'Reilly Media, Inc., 2004.
- [39] J. O'Hara, "Toward a commodity enterprise middleware," *Queue*, vol. 5, no. 4, Article ID 1255424, pp. 48–55, 2007.
- [40] F. Alt, S. Schneegass, M. Girgis, and A. Schmidt, "Cognitive effects of interactive public display applications," in *Proceedings of the 2nd ACM International Symposium on Pervasive Displays (PerDis '13)*, pp. 13–18, ACM, Mountain View, Calif, USA, June 2013.
- [41] C. Bauer and S. Spiekermann, "Conceptualizing context for pervasive advertising," in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds., Human-Computer Interaction, pp. 159–183, Springer, London, UK, 2011.
- [42] P. Tran, P. Greenfield, and I. Gorton, "Behavior and performance of message-oriented middleware systems," in *Proceedings of the 22nd International Conference on Distributed Computing Systems Workshops*, pp. 645–650, Vienna, Austria, 2002.
- [43] P. Maheshwari and M. Pang, "Benchmarking message-oriented middleware: TIB/RV versus SonicMQ," *Concurrency and Computation: Practice and Experience*, vol. 17, no. 12, pp. 1507–1526, 2005.



Hindawi

Submit your manuscripts at
<http://www.hindawi.com>



A.3. Anexo A3

A.3. Anexo A3

Recommender System supported on a Smart TV

– Smartphone cooperation framework for pervasive advertisement environments

F. Martinez-Pabon, J. Ospina-Quintero, J. Caicedo-Guerrero, G. Ramirez-Gonzalez *Member*,
GIT (Telematics Engineering Group – University of Cauca)

Abstract— Ads recommendations delivery on digital signage environments should consider group and individual user profiles, but the information about the trust inferred from the social circle of the users is also valuable as a modern way of word of mouth. Although the ads recommendation precision is relevant and frequently explored, a good novelty/precision balance must be a concern on pervasive advertisement environments; as a matter of fact, it is not only a RS algorithm issue itself, but also a better display strategy matter. This paper introduces a public display recommender system approach based on an individual-group cooperation model implemented throughout a Smart TV – Smartphone interaction scheme.

Keywords Recommender systems, Pervasive advertising, Trust inference, Digital signage.

I. INTRODUCCION

Recently, the pervasive advertising, understood as the use of pervasive computing technologies for advertising purposes, is an interesting emergent field for big, medium and small companies. Although several approaches have been designed to deliver advertisements to potential clients throughout their personal devices (Smartphones, tablets or PC), even the public spaces are attractive taking into account that the 75% of the purchase decisions are taken at the sale places or near of them [1] [2]; this field, known as Digital Signage, is related with digital content display using public screens [3]. However, for the purpose of this proposal the public displays environments motivate the analysis of three specific issues: first, the personalization and context adaptation, which has been frequently addressed from the Recommender Systems (RS) perspective; second, the ads must be addressed not only to individuals but also to a group of people; finally, the precision of the recommendations is a metric frequently evaluated on RS researches, but the extent of novelty is also important on the advertising domains as part of the persuasion; so, a balance between precision and novelty is a desirable feature.

About the first issue, although several variables may influence the context user, the analysis of the social context deserves an special attention. During years, the “word of mouth” has been a powerful technique for marketing purposes, so the inclusion of the user social context information in the recommendation algorithm (specifically, the trust in other users) may be a mechanism for getting ads influence from other users in the closest social circle. The traditional collaborative filtering used in the RS, calculate recommendations from users similarities in their ratings, but at the end, they are anonymous users. The inclusion of social context information may improve the ads recommendation

process with persuasion purposes, knowing that 67% of purchase decisions are influenced by close people opinions. Although some researches have built proposals for the inclusion of information of the social circle of the user, frequently they are based on explicit mechanisms to infer the trusts between users [4], [5] or they try to infer this same information from the ratings matrix itself [6]. Accordingly, these approaches at the end infer the trust information from proprietary social networks with the user intervention or infer the trust from ratings that in most of cases belongs to anonymous users.

About the second issue, the recommendation process for a group of people implies a new set of challenges related with the possible ad-hoc groups conformation, the user preferences acquisition and the recommendations generation itself; these challenges have been addressed for several researches throughout the use of special aggregation techniques during the recommendation process, which try to average the individual users preferences to build a group recommendation model. However, the recommendation process improvement in these cases may be not only a matter of the RS algorithm behavior itself, but also a better display strategy issue. Most of public displays interaction initiatives do not consider multi-screen approaches were the content is distributed between the screens in a complementary way; a screen content replication has been used instead. It is also related with the third issue, because a better display strategy also may contribute positively to the novelty perception: by definition, the group recommendations displayed in a public screen will be less personalized than the recommendations displayed in a personal device (e.g. Smartphone or tablet), so they could be more novel for the users. In this sense, the recent Smart TV model becomes interesting for this model implementation because its intrinsic and seamless connection capabilities with nearby devices like Smartphones and tablets; although some researches have proposed some alternatives to group recommendations [7] and/or public screens interaction schemes, [8] the research about a Public Screen – Smartphone cooperation model from a precision/novelty balance perspective for advertising purposes is still incipient. On the other hand, most of the researches have addressed the RS evaluation from a precision metrics approach, so a novelty/precision evaluation scheme must be defined for this new approach.

This research proposes a public display RS approach for digital signage environments based on an individual-group cooperation model that involves information from the user social circle, implemented throughout a Smart TV – Smartphone interaction scheme. From the three specific issues

described previously, the main contributions of the current proposal may be summarized as follows: i) a social context awareness recommender system for advertising purposes, including implicit mechanisms to infer trust from a social network; ii) a Smart TV – Smartphone cooperation framework to support multi-screen recommendations delivery as a method to improve the novelty/precision balance in an individual/group cooperation model; iii) a reference method to evaluate the recommender system from a novelty/precision perspective.

II. PROPOSAL DESCRIPTION

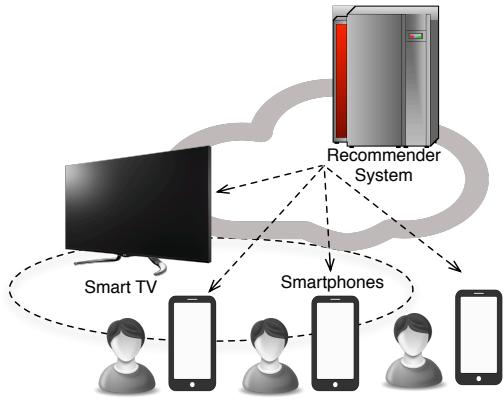


Figura 1. Recommender System general architecture

The reference architecture for the model implementation is shown in Figure 1. Traditionally, the digital signage spaces use public displays with static information using a broadcast approach or some interaction approaches using mobile devices, but they do not use a multi-screen paradigm, so the smartphone or tablet screen is not fully functional because they are not displaying complementary information. This model proposes a Smart TV – Smartphone cooperation scheme, so the Smart TV behaves as a public screen displaying recommendations for the group of users that are in front of the TV as long as the Smartphone screen is used to display ads according to the preferences of each user [9]. Using this scheme, it is expected more precision for the ads in the Smartphone but also an interesting bigger extent of novelty for recommendations on the TV screen, because the aggregation techniques will try to satisfy the preferences of a group of users by averaging individual preferences, which may not be accurate recommendations for each user, but they may result on novel ads instead, something valuable for pervasive advertising environments.

The recommender system algorithms have been rebuilt to include contextual information, specifically the information about the trust inferred from the user close social circle. Basically, the proposed recommendation algorithm has two main components: i) a component that evaluates the similarity between the users (based on the classic collaborative filtering technique) and ii) a component that evaluates the trust between users, which is inferred from the Facebook social network. According to this approach, this proposal not only uses the matrix ratings but also an external source for inferring

the trust between users, in this case a popular social network.

$$WTS_{a,u} = W_t \times T_{a,u} + W_s \times S_{a,u}$$

Wt: trust weight; Ws: Similarity weight; Ta,u: Trust coefficient (user a, u); Sa,u: Similarity coefficient (user a, u)

At a high level, the algorithm includes a weight for similarity and trust components, so its performance can be tuned to specific requirements. The trust inference component generates a score for the trust between users according to the analysis of the interaction information in Facebook; according to previous findings, the interaction information is the best source to infer trust between users. In this way, the user access to the system using a “login with Facebook feature”, so the trust inference process is performed implicitly without a manual user intervention.

III. EXPERIMENTAL FRAMEWORK

An experimental framework was designed to make an overall evaluation of the recommender system according to the features of the proposed Smart TV – Smartphone cooperation model. This framework was based on the proposal of [10]. In summary, two kinds of tests were specifically designed: offline tests, where datasets are used to validate the algorithms behavior and online tests, where real users interact with the system to capture their perception about the model implementation [11] [12]. Two basic hypotheses were designed to guide the experimentation process:

H1: the trust information inclusion in the collaborative filtering technique improves the precision/novelty balance of the recommendations.

H2: the inclusion of multi-screen cooperation schemes to enable the delivery of group and individual recommendations improves the precision/novelty balance.

At a first stage, a dataset with information about products and services ads was developed with the collaboration of students of the Tourism program of University of Cauca. The objective of this first phase was to build a low sparse and editable dataset to make offline tests about the performance of some RS algorithms; later, a group of 49 students (21 men and 28 women ranging between 20 and 24 years old) post and rate items using the Smart TV and Smartphone cooperation framework during the online tests. At the end, 137 items and 2190 ratings were considered for the dataset using a scale from 1 to 5 for ratings. With this purpose in mind, a small prototype was developed and tested in an academic environment. The prototype basis was to implement an electronic alternative to a traditional static ads board, where users post ads using paper posters; these boards are frequently found in small shops or academic campus. The alternative implementation replaces the old board by a new cooperative Smart TV – Smartphone model, where both devices screens are offering ads to users under different but complementary approaches: ads recommendations for group profiles on TV screen and ads recommendations for individual profiles on the

Smartphones screens. Moreover, interaction capabilities between both devices were provided to change the static behavior of the traditional board [13].

This first experiment was addressed to test the H2. The first results confirm the hypothesis about the positive effect of the multi-screen paradigm over the novelty/precision perception. Currently, there is a similar developing experiment for testing H1, including trust inference information during the recommendation process; in this case, two target groups of volunteers from University of Cauca and Innovagen Foundation were tested to study their social behavior and select a suitable group for trust inference purposes. Additionally, a model adaptation to measure the novelty effect is in progress.

III. CONCLUSION

This research proposes a new approach for recommender systems in the digital signage domain that includes an improvement to the recommendation algorithm itself by including contextual information from the social circle of the user and also a better display strategy using a multi-screen paradigm based on a Smart TV – Smartphone cooperation model that contributes to the improvement of the precision/novelty balance. The inclusion of other contextual variables and the improvement of the aggregation techniques for group recommendation purposes are interesting topics of further research.

ACKNOWLEDGMENTS

This work was supported by the University of Cauca throughout the projects VRI 3593 “SMARTA: Modelo para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone” and VRI 4045 “MANTISS: Modelo para la adaptación de contenidos publicitarios en entornos n-screen interactivos soportados en un esquema de colaboración Smart TV – Smartphone”. Francisco Martinez is funded by Colciencias Doctoral scholarship N. 567.

REFERENCIAS

- [1] C. Bauer and S. Spiekermann, “Conceptualizing Context for Pervasive Advertising,” in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 159–183.
- [2] F. Martinez-Pabon, G. Ramirez-Gonzalez, and Á. Chantre-Astaiza, “Conceptual model for pervasive advertising supported on a Smart TV - Smartphone cooperation framework,” *Cienc. E Ing. Neogranadina*, vol. 24, no. 1, pp. 116–142, Jan. 2014.
- [3] U. Stalder, “Digital Out-of-Home Media: Means and Effects of Digital Media in Public Space,” in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 31–56.
- [4] J. Golbeck, “Generating Predictive Movie Recommendations from Trust in Social Networks,” in *Trust Management*, K. Stolen, W. H. Winsborough, F. Martinelli, and F. Massacci, Eds. Springer Berlin Heidelberg, 2006, pp. 93–104.
- [5] P. Avesani, P. Massa, and R. Tiella, “Moleskiing. it: a trust-aware recommender system for ski mountaineering,” *Int. J. Infonomics*, vol. 20, 2005.
- [6] N. Lathia, S. Hailes, and L. Capra, “Trust-Based Collaborative Filtering,” in *Trust Management II*, Y. Karabulut, J. Mitchell, P. Herrmann, and C. D. Jensen, Eds. Springer US, 2008, pp. 119–134.
- [7] B. Carolis, “Adapting News and Advertisements to Groups,” in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 227–246.

[8] P. Santos, F. R. Ribeiro, and J. Metrolho, “Using pervasive computing technologies to deliver personal and public ads in public spaces,” in *2012 7th Iberian Conference on Information Systems and Technologies (CISTI)*, 2012, pp. 1–6.

[9] F. Martinez-Pabon, J. Caicedo-Guerrero, J. J. Ibarra-Samboni, G. Ramirez-Gonzalez, and D. Hernandez-Leo, “Smart TV-Smartphone Multiscreen Interactive Middleware for Public Displays,” *Sci. World J.*, vol. 2015, p. e534949, Apr. 2015.

[10] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” *ACM Trans Inf Syst*, vol. 22, no. 1, pp. 5–53, Jan. 2004.

[11] F. Martinez-Pabon, J. C. Ospina-Quintero, V. Garzon-Marin, A. Chantre-Astaiza, M. Muñoz-Organero, and G. Ramirez-Gonzalez, “Enriching Public Displays Ads Recommendations Using an Individual: Group Cooperation Model,” in *Proceedings of The International Symposium on Pervasive Displays*, New York, NY, USA, 2014, pp. 186:186–186:187.

[12] F. Martinez-Pabon, J. Caicedo-Guerrero, J. J. Ibarra-Samboni, G. Ramirez-Gonzalez, M. Muñoz-Organero, and A. Chantre-Astaiza, “Smart TV – Smartphone Cooperation Model on Digital Signage Environments: An Implementation Approach,” presented at the MOBILITY 2014, The Fourth International Conference on Mobile Services, Resources, and Users, 2014, pp. 25–31.

[13] F. Martinez-Pabon, V. Garzon-Marin, J. C. Ospina-Quintero, J. J. Ibarra-Samboni, J. Caicedo-Guerrero, A. Chantre-Astaiza, and G. Ramirez-Gonzalez, “Sistema de recomendaciones para entornos de Digital Signage soportado en un esquema de cooperación Smart TV-Smartphone,” *Rev. Ing. Univ. Medellín*, vol. 24, no. 13, pp. 181–196.



Francisco Martinez-Pabon received the Engineering degree in Electronics and Telecommunications from Universidad del Cauca, Colombia, in 2003 and has a Master degree in Telematics Engineering in the same university. Currently, he is a PhD student in Telematics Engineering in the same University. He received the acknowledgment as Nokia Developer Champion from 2012 to 2014. His current research interests are the recommender systems, social networks analysis and mobile computing.



Juan Camilo Ospina-Quintero received the Engineering degree in Electronics and Telecommunications Engineering from Universidad del Cauca, Colombia, in 2012, and is a Master student in Telematics Engineering in the same University. His current research interests are recommender systems and social networks analysis.



Jaime Caicedo-Guerrero received the Engineering degree in Electronics and Telecommunications Engineering from Universidad del Cauca, Colombia, in 2006, and is a Master student in Telematics Engineering in the same University. His current research interests are mobile applications, digital signage, public displays and Smart TV.



Gustavo Ramirez-Gonzalez received the engineer degree in Electronic and Telecommunications Engineering from the University of Cauca – Cauca, Colombia, in 2001, and has a Master in Telematics Engineering in the same university. He received his Doctorate degree in Telematics Engineering from the Carlos III University in Spain, in 2010. Currently, he is a professor and researcher at the Department of Telematics at the University of Cauca. He has participated in national and international projects in Colombia and Spain. His research interests are mobile computing, ubiquitous computing, mobile learning and advanced telecommunications services.

A.4. Anexo A4

A.4. Anexo A4

Collaborative Learning Orchestration Using Smart Displays and Personal Devices

Kalpani Manathunga^{1()}, Davinia Hernández-Leo¹, Jaime Caicedo², Jhon Jairo Ibarra², Francisco Martinez-Pabon², and Gustavo Ramirez-Gonzalez²

¹ ICT Department, Universitat Pompeu Fabra, Barcelona, Spain
`{kalpani.manathunga, davinia.hernandez}@upf.edu`

² Departamento de Telemática, Universidad del Cauca, Popayán, Colombia
`{jcaicedo, jjibarra, fomarti, gramirez}@unicauca.edu.co`

Abstract. Pervasive classroom environments with interconnected smart devices permit enacting diverse pedagogical models in education. This paper proposes an extensible architecture integrating smart display, smart phones and wearable devices to support flexible orchestration of dynamic collaborative learning activities in face-to-face educational scenarios. The paper motivates an architectural design and describes its main components based on existing systems like Signal Orchestration System (SOS) and a multi-screen cooperation middleware. An applicable scenario illustrates the usage of proposed architecture in which wearable devices are used to indicate orchestration mechanisms (group formation, change of activity), a shared display visualizes tasks with summary of the orchestration and activity progress for collective awareness and smart phones are used to interact with the shared display and complete the activities.

Keywords: CSCL · Classroom orchestration · Devices for seamless learning

1 Introduction

Learning in groups or collaborative learning (CL) leads to effective learning when mediated by productive social interactions as many studies had shown [1–3]. In recent past research on integrating collaborative activities within physical classrooms and blended learning scenarios had drawn attention in the domain of Computer Supported Collaborative Learning (CSCL) [1]. Collaborative Learning Flow Patterns (CLFP) like Jigsaw or Pyramid are known as best practices [2] that specify how to structure (orchestrate) the CL activities on aspects like group formation based on policies, role allocation and resource distribution. When enacting CL activities, a traditional classroom could be converted into a smart space by seamlessly integrating interactive displays and devices [3]. Live didactic mechanisms and dynamic orchestration approaches catch student's attention and interest [2, 4, 5] if addressed with sufficient flexibility [6]. Existing classrooms are already equipped with shared display units like projectors and smart boards. Yet, converting these displays to be smart awareness boards that can be used to orchestrate activities in cooperation with smart phones and wearable devices has been addressed less [1, 3].

This paper proposes an architectural solution to enact CL activities forming a smart classroom with prevailing artifacts and previously proposed technologies.

2 Opportunities for Smart Classrooms: CL Orchestration

Smart classrooms have been devised for different purposes including enabling extended tele-education, diverse learning activities and facilitating implementation of classroom dynamics. For example, Shi et al. [4] proposed a smart classroom design integrating voice-recognition, computer vision and other smart devices to provide tele-education experience in a real class. Another attempt used smartphones to enact an innovative collaborative activity to teach physics within a classroom [7]. Wearable devices and interactive furniture have been proposed as physical computing approaches to enhance classroom orchestration by indicating organizational aspects to students [3] or visualizing feedback about their progress to the teachers [5]. Yet, support for dynamic orchestration taking advantage holistically of smart classroom technology (including collective display devices, personal devices, etc.) has not being addressed. This paper highlights potential opportunities of integrating different devices (smart phones, wearable devices, collective displays, etc.) seamlessly with CL orchestration services implying pervasive computing methods to organize face-to-face CL activities in the classroom. These opportunities include displaying activity details and configurations to clarify tasks (e.g., in mobile phones); promote social awareness of progress among students and teachers (e.g., via shared classroom displays); indicate CL flow mechanisms, such as group formation, distribution of roles and resources, see for instance the CLFPs [2] (e.g., in wearable devices); facilitating dynamic modifications when required [8] supported by the transfer of the activity status and automatic configuration of the devices (through orchestration services comprising a “classroom middleware” interconnecting the devices).

3 Architectural Elements

The proposed architecture for holistic CL classroom orchestration is composed of systems proposed by the authors in previous research [3, 9] which are already devised [3] or has potential [9] to support classroom orchestration. The architecture proposes CL orchestration services with open APIs, enabling the extension of the architecture with the integration of additional classroom technologies [5]. Figure 1 shows the main components which relies on features of two service layers. First, orchestration services of the Signal Orchestration System (SOS) [3], which compute orchestration mechanisms to be transmitted as orchestration signals to SOS wearable devices (physical forearm bracelets rendering e.g., color signals indicating grouping, vibration signals for change of activities). Second, the Smart TV–Smart phone interaction middleware [9] enables a multi-screen cooperation model [10] based on loosely coupled publish/subscribe paradigm for message exchange. The Smart TV screen (or any HDMI-compliant display in the classroom) is complemented by mobile devices bringing seamless interaction capabilities rather than being only a display unit. The middleware integration enables

coherent global orchestration of CL activities replicating relevant orchestration indications in different displays, when appropriate, or showing complementary information as suitable considering the affordances of the displays and the characteristics of the activities. The seamless transfer of orchestration status between devices enables dynamic modifications of the CL flow.

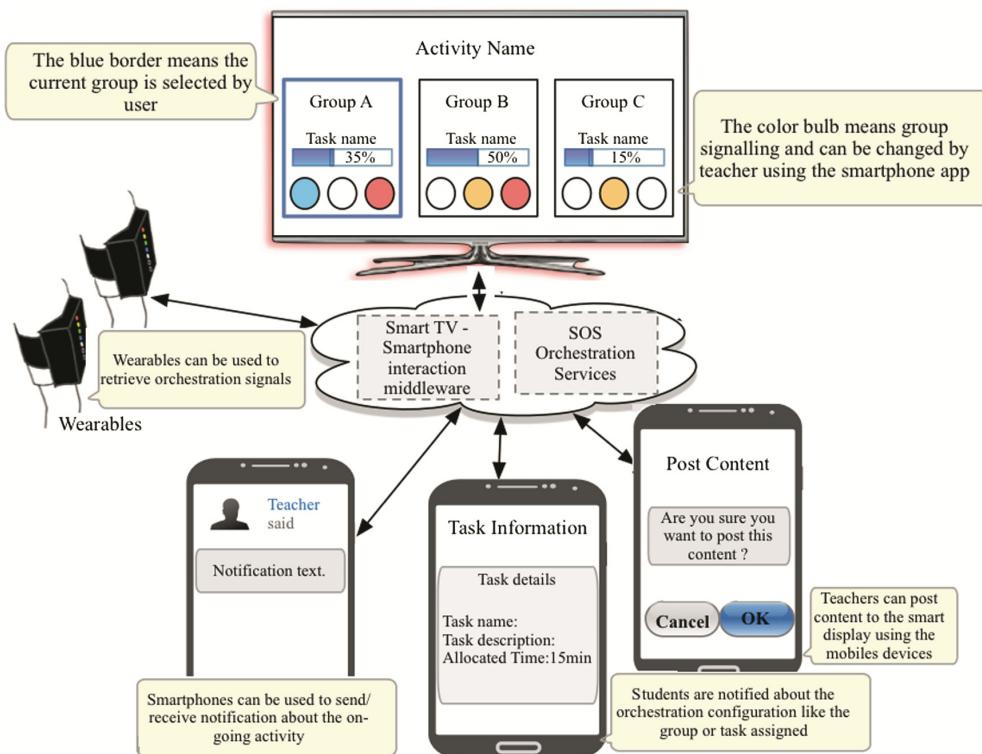


Fig. 1. Components of SOS and smart devices integration

4 Illustrative Scenario

Following scenario illustrates applicability of proposed architecture using Jigsaw CLFP [2] at a secondary educational context; yet can be extrapolated to other subject matters and educational levels. The application of the architecture is also of interest with other CLFPs. Jigsaw pattern promotes positive interdependence and individual accountability by dividing a problem into sub-problems, allocating sub-problems to individuals, forming expert groups (to address sub-problems) and jigsaw groups (groups with experts on each sub-problem, addressing the global problem).

In a secondary school curriculum students are required to gain knowledge while being able to critically contrast the three main different climates in Spain. To achieve this learning objective, the teacher designs a Jigsaw-inspired learning activity that spans for two classes which requires individuals do prepare at home for assigned climate zone provided they know their groups on the first day. The activity continues next day with the expert and jigsaw phases (supported by SOS wearable devices, mobile phones and

smart display). When teacher configures sub tasks (3, in this) and uploads student list (30) using SOS manager, the services compute distribution of sub-problems and groupings (10 students read each sub-problem; 3 or 6 expert groups with 10 or 5 members with same sub-problem; 5 or 10 jigsaw groups with 3 or 6 members). In the class groupings are illustrated in the smart display for students to know peers. Further details required for the activity can also be visualized in the display and students can interact using smart phones. During activity enactment, expert groups are displayed enabling quick grouping, but teacher notices that 2 students are absent from previous class and requires regrouping to comply with Jigsaw constraints. SOS manager facilitates this and new expert groups would be 6 groups – 2 with 4 members and 5 with 5 members, and only 7 jigsaw groups with 3 or 4 members being at least one of them an expert on a sub-problem and these dynamic changes are reflected on-the-fly to the smart display. Students are not confused if peers are missing and they see the new group structure. Orchestration indications (vibration signal to indicate change of activity or color signals for phase changes or space allocation) are propagated to the wearable devices. Teacher posts questions to the experts to monitor knowledge and students answer using smart phones and their progress/performance is indicated in the smart display. Students make annotations of their discussions in phones, which are, later visualized in the shared display for a collective discussion.

5 Conclusion

This paper proposes a holistic view of technology-supported CL orchestration in the classroom that exploits use of personal devices (smart phones, wearable devices) and shared displays. The paper describes elements of an extensible architecture with services (computing CL orchestration mechanisms) and a multi-screen cooperation middleware (interaction and data flow with/between screens) based on previous work. The illustrated scenario shows the integrative use of wearable devices to indicate group formation, mobile phones to inform and support tasks, smart displays to offer awareness about activity progress and visualize individual and collective assignments with interactions. Future work includes evaluation and extensions of the architecture considering other classroom technologies and virtual learning environments.

Acknowledgments. This work was supported by the Spanish Government (EEE TIN2011-28308-C03-03) and the University of Cauca (VRI 4045 “MANTISS”).

References

1. Dillenbourg, P., Järvelä, S., Fischer, F.: The evolution of research on computer-supported collaborative learning. In: Balacheff, N., Ludvigsen, S. (eds.) *Technology- Enhanced Learning: Principle and Products*, pp. 3–19. Springer, The Netherlands (2009)
2. Hernández-Leo, D., Villasclaras-Fernández, E.D., Jorrín-Abellán, I.M., Asensio-Pérez, J.I., Dimitriadis, Y., Ruiz-Requies, I., Rubia-Avi, B.: Collage, a collaborative learning design editor based on patterns. *J. Educ. Technol. Soc.* **9**(1), 58–71 (2006)

3. Hernández-leo, D., Nieves, R., Arroyo, E., Rosales, A., Melero, J., Blat, J.: SOS : orchestrating collaborative activities across digital and physical spaces using wearable signaling devices. *J. Univers. Comput. Sci.* **18**(15), 2165–2186 (2012). doi:[10.3217/jucs-018-15-2165](https://doi.org/10.3217/jucs-018-15-2165)
4. Shi, Y., Xie, W., Xu, G., Shi, R., Mao, Y., Liu, F.: The Smart Classroom: merging technologies for seamless tele-education. *IEEE Pervasive Comput.* **2**(2), 47–55 (2003)
5. Alavi, H.S., Dillenbourg, P.: An ambient awareness tool for supporting supervised collaborative problem solving. *IEEE Trans. Learn. Technol.* **5**(3), 264–274 (2012)
6. Dillenbourg, P., Tchounikine, P.: Flexibility in macro-scripts for computer supported collaborative learning. *J. Comput. Assist. Learn.* **23**(1), 1–13 (2007)
7. Echeverría, A., Nussbaum, M., Calderón, J.F., Bravo, C., Infante, C.: Face-to-face collaborative learning supported by mobile phones. *Interact. Learn. Environ.* **19**(4), 351–363 (2011)
8. Pérez-Sanagustín, M., Burgos, J., Hernández-Leo, D., Blat, J.: CLFP intrinsic constraints-based group management of blended learning situations. In: Daradoumis, T., Caballé, S., Juan, A.A., Xhafa, F. (eds.) *Technology-Enhanced Systems and Tools for Collaborative Learning Scaffolding*. SCI, vol. 350, pp. 115–133. Springer, Heidelberg (2011)
9. Martínez-Pabón, F., Caicedo, J., Ibarra, J.J., González, G.R., Organero, M.M., Astaiza, A.C.: Smart TV-smartphone corporation model on digital signage environments: an implementation approach. In: *4th International Conference on Mobile Services, Resources and Users*, pp. 25–31, Paris (2014)
10. Yoon, C., Um, T., Lee, H.: Classification of N-Screen services and its standardization. In: *14th International Conference on Advanced Communication Technology*, pp. 597–602 (2012)

A.5. Anexo A5

A.5. Anexo A5

Smart TV – Smartphone Cooperation Model on Digital Signage Environments: An Implementation Approach

Francisco Martinez-Pabon
Telematics Engineering Group
University of Cauca
Popayán, Colombia
fomarti@unicauca.edu.co

Gustavo Ramirez-Gonzalez
Telematics Engineering Group
University of Cauca
Popayán, Colombia
gramirez@unicauca.edu.co

Jaime Caicedo-Guerrero
Telematics Engineering Group
University of Cauca
Popayán, Colombia
jcaicedo@unicauca.edu.co

Mario Muñoz-Organero
GAST Group
Carlos III University of Madrid
Madrid, España
mario.munoz@uc3m.es

Jhon Jairo Ibarra-Samboni
Telematics Engineering Group
University of Cauca
Popayán, Colombia
jjibarra@unicauca.edu.co

Angela Chantre-Astaiza
GITUR Group
University of Cauca
Popayán, Colombia
achantre@unicauca.edu.co

Abstract—Modern pervasive digital signage environments demand capabilities beyond the interaction schemes, frequently implemented throughout personal area network technologies or touchscreen features. Smart TV emerges as an interesting alternative model for public displays and Smartphone cooperation, in order to implement a multi-screen approach that complements the task of ads recommendation algorithms for a group of people watching the screen. This paper introduces an implementation approach for a Smart TV – Smartphone cooperation model in digital signage environments using a multi-screen paradigm.

Keywords - Pervasive advertising; digital signage; Smart TV; cooperation model.

I. INTRODUCTION

Advertising has played an important role in the commerce from its origins; as part of the promotion, one of the marketing areas, the advertising is defined as “any paid form of non-personal presentation and promotion of ideas, goods or services by an identified sponsor” [1]. Recently, a new paradigm known as pervasive advertising, which refers to the use of pervasive computing technologies for advertising purposes [1], has arisen as a promising bet for modern advertisers and consumers. Although most of pervasive advertising approaches has been addressed to mobile devices (Smartphones or tablets), even the public spaces are very interesting for the industry, taking into account that the 75% of the purchase decisions are taken at the purchase places or near of them [2]; this field, known as Digital Signage, it is related to digital content display using public screens [3].

Traditionally, the public screens have been static and non-personalized devices, but modern approaches have enabled the public displays inclusion on pervasive environments. Specifically, the Smart TV model emerged in 2010 throughout the initiative of big vendors such as Samsung, LG, Sony and Intel to build televisions and set-top boxes with more processing power and a better Internet

integration [4]. The results for this emergent model are not only limited to free internet access and customization capabilities throughout applications download, but also a valuable capability for connecting and sharing content via standards like Universal Plug and Play (UPnP) or Digital Living Network Alliance (DLNA) [5] with other devices like Smartphones or tablets; this feature is extremely interesting for advertising environments. Although several researches have developed interaction schemes between public displays and mobile devices using personal area network technologies like Bluetooth or Near Field Communication (NFC), even the research for Smart TV model incorporation is incipient. On the other hand, pervasive digital signage environments face other challenges related to customized ads for a group of people watching the screen; traditionally, this issue has been addressed from Recommender System (RS) perspective, which applies search and information filtering techniques to provide users with personalized suggestions about a set of items in a particular domain [6]. However, the perceived serendipity and accuracy about ads recommendations may be not only a matter of the RS algorithm itself, but also a better display strategy issue. Most of public displays interaction initiatives do not consider multi-screen approaches were the content is distributed between the screens in a complementary way; a screen content replication has been used instead.

This paper proposes an implementation approach for a Smart TV – Smartphone cooperation model in digital signage environments using a multi-screen paradigm supported on a flexible protocol. Section 2 summarizes some related work. Section 3 presents a reference architecture for the proposed cooperation model and summarizes some aspects related to the protocol design. Section 4 describes some experimentation results from the user perceived satisfaction perspective. Finally, Section 5 provides some conclusions and future work.

II. STATE OF ART

The research about pervasive advertising involves several interesting topics related to the most important challenges in its implementation. Although several research works have focused on mobile environments where mobile devices are the main tool for advertising purposes, the modern digital signage environments demand the study of new interaction schemes between Smartphones and public displays. Next, some relevant works related to the context of this article will be presented.

At first, some interesting experiences about interactive public displays have been developed around the world. For example, the University of Oulu, in Finland, installed thirteen interactive LCD-screens in several public places across the city, which have been updated and studied since 2009 [7]. The users could interact with the screens by using the touchscreen or their mobile devices. In a similar way, the University of Lancaster, England, installed interactive displays in the small village of Wray [8]. The displays allowed people to upload photos about the village's history and later some capabilities for advertisements uploading about village's services and products were added. Meanwhile, the University of Stuttgart in Germany developed an interesting study about the factors for a successful public digital display environment for advertising purposes [7]. However, these experiments neither consider the use of Smart TV as Interactive Public Display nor interaction schemes throughout Smartphones that enable multi-screen features.

On the other hand, several approaches have been studied for years about content adaptation and collaboration schemes. For example, [9] analyses the interaction between Smartphones and public displays throughout gestures that are used during a screen replication and [10] introduces a touch screen interaction supported on NFC capabilities, but a collaborative interaction between devices is not considered in both approaches. Otherwise, [11] outlines an overview of some functions for a Smart TV – Smartphone interaction, but a reference implementation is not provided. Other researches consider some collaboration models for including zoom functions for the main screen content on the mobile devices [12][13] and some of them consider some phone sensor functionalities [14][15]. Nonetheless, the pervasive advertising in public spaces faces other challenges related to personalized recommendations when a group of people is watching the main screen. Traditionally, this issue has been addressed from the Recommender Systems perspective. Regarding to group recommendations several approaches have been developed: Jameson [16] analyses the issues related to groups recommendations and Masthoff [17] discuss some strategies known as aggregation techniques, which try to aggregate (averaging) individual preferences models in order to create a group model to deliver the recommendations. Other systems related to this approach, like Polylens [18], a particular MovieLens system version, recommends movies based on an algorithm that combines recommendation lists for individual users and sort them in decreasing order. Other similar approaches may be found in

[19][20]. Carolis [21] developed a proposal for a pervasive advertising environment using an aggregation approach for recommending ads to the people working at a gym. The ads were displayed on public screens and also on mobile devices but basically they were replied and there was no an interaction mechanism between them. The context of this paper analyzes the personalized ads recommendations provision in public spaces throughout a Smart TV – Smartphone cooperation approach that complements the RS perspective, in order to improve the users perceived satisfaction using interaction and multi-screen display approaches that favors the RS algorithms results assimilation.

III. COOPERATION MODEL REFERENCE ARCHITECTURE

According to the state of art, traditionally the digital signage spaces use public displays with static information following a broadcast approach or some interaction approaches using mobile devices, but they do not use a multi-screen paradigm, so the smartphone or tablet screen capabilities are somewhat wasted. The cooperation model architecture proposes a Smart TV – Smartphone cooperation scheme in which the Smart TV behaves as a public screen displaying recommendations adapted for the group of users that are in front of the TV as long as the Smartphone screen is used to display ads according to the preferences of each user individually. The purpose of this scheme is to take advantage of the full capabilities of each device, using a multi-screen cooperation paradigm, so the TV information is not replied to the Smartphone screen; instead, a complementary information about ads is always displayed on the mobile device, offering more details about a specific offer in the TV screen or giving a more personalized set of items according to the individual profile of the user. Figure 1 shows the reference architecture proposed for Smart TV-Smartphone cooperation model.

A Recommender System (RS) is used for ads suggestion on both Smart TV and mobile device screen. The RS applies search and information filtering techniques to provide users with personalized suggestions about a set of items in a particular domain, in this case advertising. Specifically, a User x User collaborative filtering approach [6] was used for customizing ads on Smartphones and aggregation techniques were used to deliver the recommendations on the Smart TV; in simple terms, the aggregation techniques try to average individual preferences models in order to create a group model [17] as it was previously defined. Although the RS techniques description is out of the scope of this paper, from the RS perspective, the expected results are extremely interesting because this display scheme favors the precision for the ads in the Smartphone. Also, a larger extent of serendipity may be perceived for the recommendations on the TV screen, because the RS uses aggregation techniques for trying to satisfy the preferences of a group of users. So, the recommendations may not be enough accurate for each user, but they may result on novel ads instead, something valuable for pervasive advertising environments with persuasion purposes.

A reference implementation for this model was developed using the Apache Mahout framework [22] for the RS and Samsung Smart TV SDK [23]; mobile application was implemented over the Android platform as long as a simple Representational State Transfer (REST) Application Programming Interface (API) was developed to handle the communication between RS and applications of Smart TV and Smartphone. The communication between the Smartphones and the Smart TV for interaction purposes was enabled throughout the UPnP protocol [24].

According to previous description, a loosely HTTP-based protocol was designed to support multiple user interactions. Standard Simple Service Discovery Protocol (SSDP) [25] messages were used to discover Smart TV Devices in order to be compliant with Samsung Smart TV SDK and Convergence Framework restrictions. A full protocol messages description may be complex for the scope of this paper, so a special emphasis will be done about the discovery, authentication and pairing mechanisms, which are essential processes to start a two-way interaction between the Smart TV and Smartphones under a multi-screen paradigm.

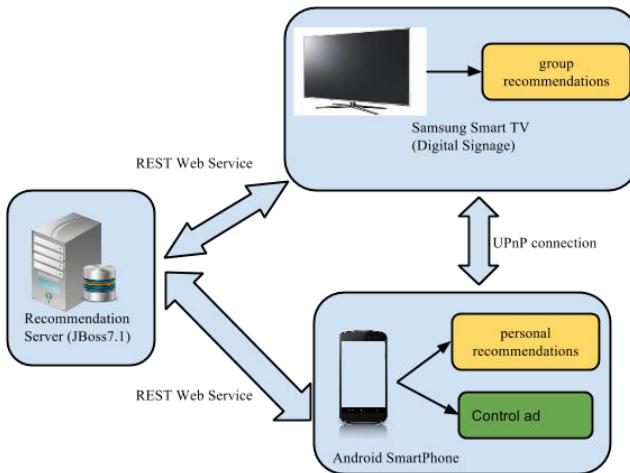


Figure 1. Smart TV – Smartphone cooperation model.

A. Discovery

Throughout this process, the Smartphone application looks for available Smart TV devices. SSDP messages defined by the UPnP standard must be used according to Samsung Smart TV Convergence Framework. A list of discovered devices is shown to user at the end of process. The complete messages flow is shown in Figure 2.

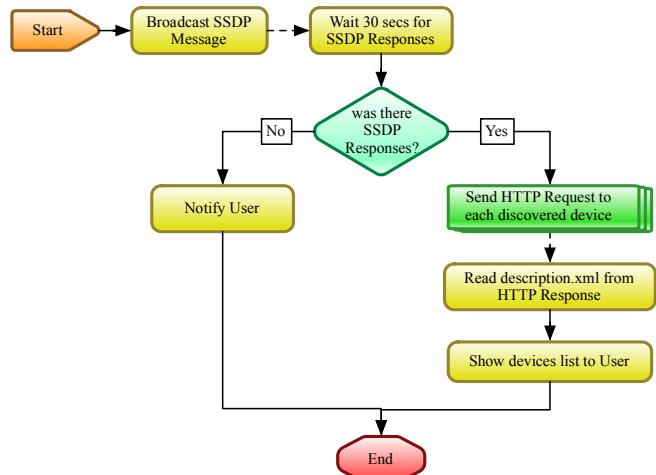
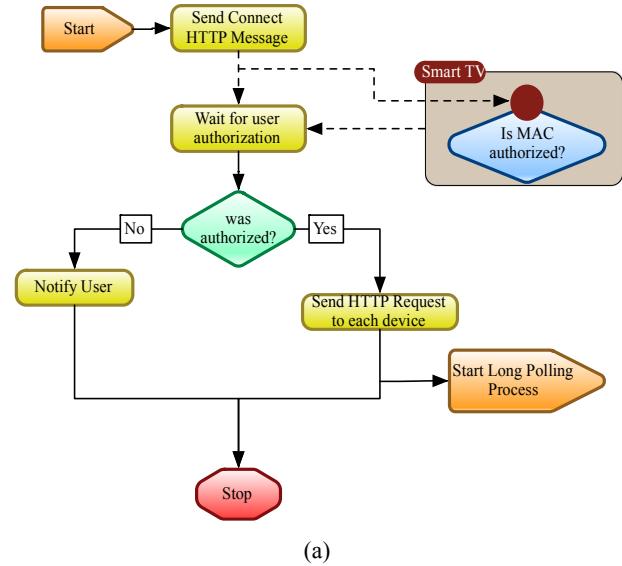


Figure 2. Discovery process.

B. Authentication and pairing

In this process, the Smartphone application requests a connection with the Smart TV. In order to be compliant with Samsung Smart TV Convergence Framework, the Smart TV device authenticates the mobile device using the MAC address (Figure 3.a). Once authorized, Smart TV and Smartphone start a long polling process to keep the connection alive (Figure 3.b).



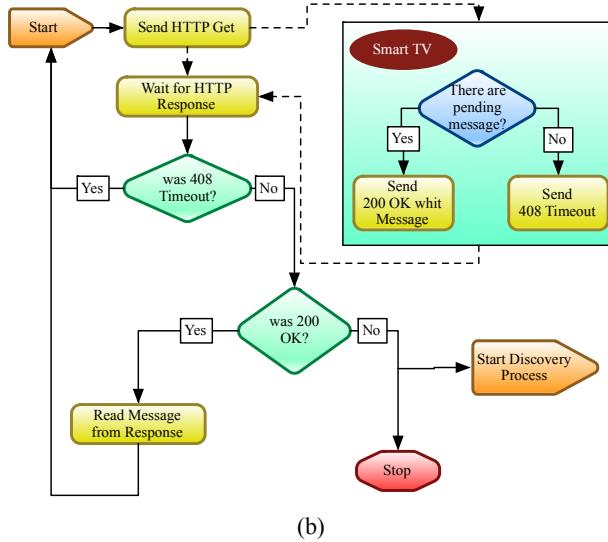


Figure 3. Authentication and pairing.

C. Login

A login process is required to identify the user in front of the Smart TV screen, so the ads may be customized for the group and individual profiles by the RS accordingly. A “login with Facebook” approach was used to make the process easier and transparent for the users. Once the user login has been completed successfully, the system assigns a color id to each connected smartphone in order to identify all users interaction with the ads on the screen (Figure 4).

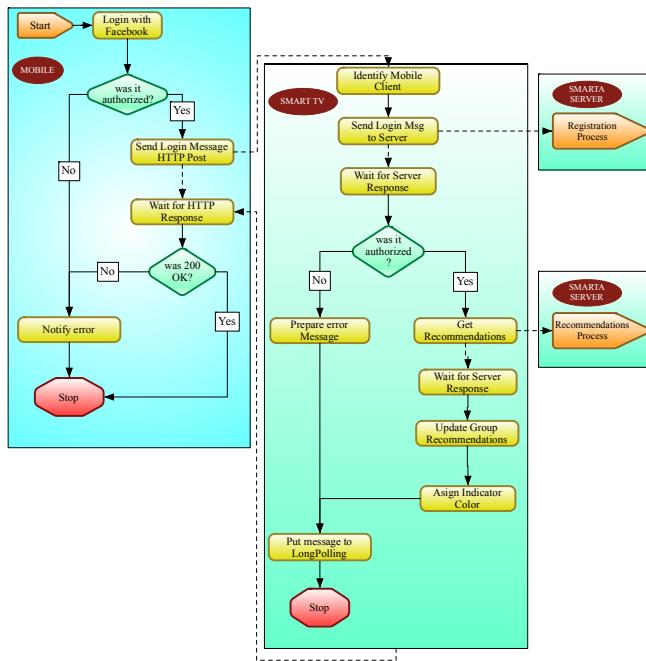


Figure 4. Login.

The other protocol messages were designed as a template for the business logic messages required for a particular

advertising application. The messages transport user actions information such as ads retrieval, ads rating or ads publishing to screen, by encoding this content using Java Script Object Notation (JSON). Table I shows a detailed package example for posting ads from the Smartphone to the Smart TV.

IV. EXPERIMENTATION

A small prototype for experimentation purposes was developed and tested in an academic environment. The prototype basis was to implement an electronic alternative to a traditional static ads board, where users post ads using paper posters; these boards are frequently found in small shops or academic campus. The alternative implementation replaces the old board by a new cooperative Smart TV – Smartphone model, where both devices screens are offering ads to users under different but complementary approaches: ads recommendations for group profiles on TV screen and ads recommendations for individual profiles on the Smartphones screens. Moreover, interaction capabilities between both devices were provided to change the static behavior of the traditional board.

In summary, the prototype application included the following functionalities: ads recommendations for a group of users watching the TV screen; ads recommendations according to individual preferences on the Smartphone screen; basic interaction between Smartphone application and Smart TV to go over the ads on TV screen from the mobile application and detail the information for a particular ad in TV screen on the Smartphone screen; post ads to system from the mobile application, mark ads as favorites and rate ads (Figure 5). Alternatively, the interaction protocol detects the users activity, so a list of top ads is displayed on Smart TV when no interaction is detected.

TABLE I. AD POST MESSAGE.

Ad post message request																	
Source – destination	Smartphone - Smart TV																
Type	HTTP POST																
Path	http://TV_IPADDR/ws/app/SMARTA/connect TV_IPADDR: Smart TV IP address																
Path parameters																	
HTTP Headers	<table> <tr> <td>SLDeviceID</td><td>Random sequence of 10 alphabetic characters</td></tr> <tr> <td>ProductID</td><td>SMARTDev</td></tr> <tr> <td>VendorID</td><td>VendorMe</td></tr> <tr> <td>msgNumber</td><td>Auto incremental sequence number for the message</td></tr> <tr> <td>Content-Type</td><td>application/json</td></tr> <tr> <td>Connection</td><td>Keep-Alive</td></tr> <tr> <td>Accept</td><td>*/*</td></tr> <tr> <td>Accept-Encoding</td><td>gzip, deflate, sdch</td></tr> </table>	SLDeviceID	Random sequence of 10 alphabetic characters	ProductID	SMARTDev	VendorID	VendorMe	msgNumber	Auto incremental sequence number for the message	Content-Type	application/json	Connection	Keep-Alive	Accept	*/*	Accept-Encoding	gzip, deflate, sdch
SLDeviceID	Random sequence of 10 alphabetic characters																
ProductID	SMARTDev																
VendorID	VendorMe																
msgNumber	Auto incremental sequence number for the message																
Content-Type	application/json																
Connection	Keep-Alive																
Accept	*/*																
Accept-Encoding	gzip, deflate, sdch																

	Accept-Language	es,en-US;q=0.8,en;q=0.6
	Transfer-Encoding	chunked
	Content-Length	Number of sent bytes in JSON format
Content	<pre>{ "type": "post", "title": "post title", "content": "post content", "img_url": "http://someurl.com" }</pre>	

Ad post message reply		
Reply codes	200	Accepted connection
	403	Not authorized to receive messages.
	404	Unknown APP_ID.
Reply content	<pre>{ "type": "post", "posted": "true/false" }</pre>	

At a first stage of the experiment, a group of 26 students from the Tourism program of University of Cauca, posted items and rated almost all of them using an alternative system, even without interacting with the Smart TV and Smartphone cooperation framework. The objective of this first phase was to build a low sparse and editable dataset to make offline tests about the performance of some RS algorithms, previously to online tests. In a second phase, a group of about 50 students posted and rated items in a 1 to 5 scale, using the Smart TV - Smartphone cooperation structure. During this phase, groups of four people were configured randomly to interact with the Smart TV using an Android Smartphone during about five minutes. During this time, users watched the ads recommendations on both screens and used the prototype functions described previously; the number of people per group was a restriction imposed by the UPnP protocol handling of Samsung SDK, but it was considered enough by experimentation purposes. Figure 6 shows some latency results for Smartphones – Smart TV connections and Figure 7 shows the estimated latency for getting ads detailed information in the Smartphone from server, once the user has chosen and ad from Smart TV screen. The tests were performed using a WiFi connection, a Samsung Smart TV 6 Series and Samsung Galaxy and LG Nexus phones with Android 4.2 or above.

At the end of the session, each student filled out a survey form where they were asked explicitly about the perceived satisfaction regarding to the ads delivered on both Smart TV and Smartphone screen. The following analysis will be focused on these results, taking the three aggregation techniques defined by Masthoff (Table II) and tested during the experiment as a starting point; the purpose is try to infer which technique supposes a better connection between the proposed Smart TV – Smartphone cooperation model and the Recommendation System.



Figure 5. Smart TV - Smartphone prototype.

The survey results showed good levels of perceived satisfaction about the ads accuracy using this cooperation scheme between TV and Smartphone screens. However, a deeper analysis was performed for the perceived satisfaction from a group profile perspective, a challenging issue for this kind of digital signage environments. Table III shows the results for the perceived satisfaction for the three techniques.

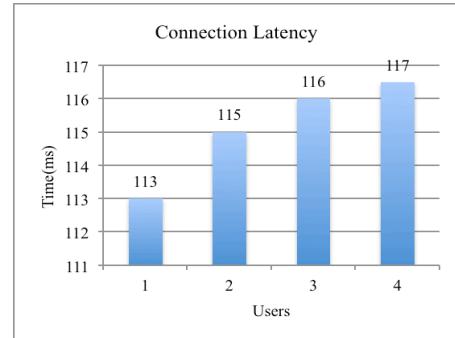


Figure 6. Connection latency.

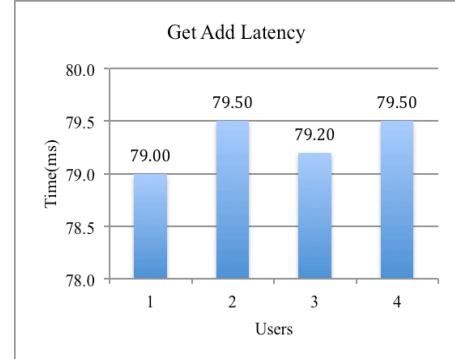


Figure 7. Getting ads latency.

TABLE II. SATISFACTION PERCEPTION.

Test No.	Aggregation technique	Description
1	Additive	Ratings are added; the larger the sum the earlier the alternative is recommended
2	Less Misery	Make a list of ratings with the minimum of the individual ratings; items are recommended based on the rating on that list, the higher the sooner. The idea is that a group is as happy as its least happy member
3	Most pleasure	Make a list of ratings with the maximum of the individual ratings; items are recommended based on the rating on that list, the higher the sooner.

The mean value suggests that less misery technique offers a best-perceived satisfaction value for users; however, it is important to find out if this difference is meaningful. Each technique was tested for a different group of users, so it is required to compare the mean difference in two independent samples. The goal is to define if the satisfaction expressed by users using a less misery technique is significantly higher than Additive or Most pleasure techniques respectively; this analysis was performed using the Two sample t technique, which is frequently used to compare whether the average difference between two groups is really significant [26]. According to this, a null hypothesis should be considered to carry out the test; in this case there are two null hypotheses: the first one proposes that the satisfaction perceived when additive technique is used, is the same when a less misery technique is used; in the same way, the second one involves less misery and most pleasure techniques. In both cases there is an alternative hypothesis, which proposes that less misery strategy offers the best-perceived satisfaction value.

TABLE III. SATISFACTION PERCEPTION.

Aggregation technique	Sample size	Mean	Standard deviation
Additive	16	$uA = 3,375$	0,957
Less misery	18	$uLM = 4,056$	0,725
Most pleasure	14	$uMP = 3,5$	0,941

Table IV shows the analysis results for both hypotheses using a significance level (p) of 5%; a p -value lower than 0.05 is a statistical evidence that approves the alternative hypothesis over the null hypothesis.

TABLE IV. 2 SAMPLE T RESULTS FOR PERCEIVED SATISFACTION.

Test	Null hypothesis	Alternative hypothesis	p-value
1	$uLM = uA$	$uLM > uA$	0,014
2	$uLM = uMP$	$uLM > uMP$	0,040

For both tests, p-values were less than 0.05; it means there is a meaningful difference about the perceived satisfaction by the users using less misery in contrast with additive or most pleasure techniques. These results suggest

that perceived satisfaction about ads recommendations for the group improves when less misery is provided to the least satisfied of its members. In this sense, the contribution of the Smart TV – Smartphone cooperation model is very relevant, because even the least satisfied member of the group has the alternative to find more customized ads recommendations on his Smartphone screen, which seems to increase the perceived satisfaction.

V. CONCLUSION AND FUTURE WORK

This paper proposes a Smart TV – Smartphone cooperation model for digital signage environments using a multi-screen and interactive approach for ads recommendations display. The design of a loosely coupled and simple protocol based on HTTP using a RESTful style and UPnP packets, provides a scalable and compatible framework for the cooperation model implementation.

On the other hand, although the recommendations to groups have been a challenging issue on digital signage environments, it has been addressed frequently from RS algorithms perspective, but the Smart TV – Smartphone cooperation model offers an alternative to complement the RS algorithms task from an information display approach. The experimentation suggests that less misery aggregation technique offers the best results in this kind of digital signage environments regarding to perceived satisfaction by users, taking into account that even the least satisfied user has the chance to improve the perceived accuracy of group recommendations displayed on TV, using his Smartphone screen.

Future work is related to the cooperation model evolution towards a more distributed middleware that overcome some restrictions related to the number of supported users and some intermittent behavior during pairing and connection mechanisms observed during the experimentation with Samsung Smart TV Convergence Framework.

ACKNOWLEDGMENT

This work was supported by the University of Cauca throughout the projects VRI 3593 “SMARTA: Modelo para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone” and VRI 4045 “MANTISS: Modelo para la adaptación de contenidos publicitarios en entornos n-screen interactivos soportados en un esquema de colaboración Smart TV – Smartphone”. Francisco Martínez is funded by Colciencias Doctoral scholarship N. 567.

REFERENCES

- [1] J. Müller, F. Alt, and D. Michelis, “Pervasive Advertising,” Springer London, pp. 1–29, 2011.
- [2] C. Bauer and S. Spiekermann, “Conceptualizing context for Pervasive Advertising,” in Pervasive Advertising, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, pp. 159–183, 2011.
- [3] U. Stalder, “Digital Out-of-Home Media: means and effects of digital media in public space,” in Pervasive Advertising, J.

- Müller, F. Alt, and D. Michelis, Eds. Springer London, pp. 31–56, 2011.
- [4] F. Jewet., “Why Smart TV is the next big thing”. Available: http://www.uievolution.com/mobileconnect/Mobile_Connect_June_2011.pdf, [Accessed: 10-Dic-2013].
- [5] DLNA.org, “Digital Living Network Alliance,” July, 2014. Available: <http://www.dlna.org>, [Accessed: 03-Jul-2014].
- [6] F. Ricci, L. Rokach, and B. Shapira, “Introduction to recommender systems handbook,” in Recommender Systems Handbook, F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, Eds. Springer US, pp. 1–35, 2011.
- [7] F. Alt, A. Schmidt, and A. Schmidt, “Advertising on public display networks,” Computer, vol. 45, no. 5, May. 2012, pp. 50–56, doi:10.1109/MC.2012.150
- [8] T. Ojala, et al., “Multipurpose interactive public displays in the wild: three years later,” Computer, vol. 45, no. 5, 2012, pp. 42–49, doi:10.1109/MC.2012.115
- [9] The Next Web, “Google’s Open Project lets you beam apps to an external display using only your smartphone’s camera,” Available: <http://thenextweb.com/google/2013/09/26/google-researches-open-project-lets-you-beam-apps-to-an-external-display-using-only-your-smartphones-camera/>, [Accessed: 06-Nov-2013].
- [10] G. Broll, E. Vodicka, and S. Boring, “Exploring multi-user interactions with dynamic NFC-displays,” Pervasive and Mobile Computing, vol. 9, no. 2, Apr. 2013, pp. 242–257, doi:10.1016/j.pmcj.2012.09.007
- [11] C. Yoon, T. Um, and H. Lee, “Classification of N-Screen services and its standardization,” Proc. 14th International Conference on Advanced Communication Technology (ICACT), 2012, pp. 597–602.
- [12] P. Baudisch, N. Good, and P. Stewart, “Focus plus context screens: combining display technology with visualization techniques,” Proc. 14th Annual ACM Symposium on User Interface Software and Technology, ACM Press, 2001, pp. 31–40. doi:10.1145/502348.502354
- [13] S. Boring, M. Jurmu, and A. Butz, “Scroll, tilt or move it: using mobile phones to continuously control pointers on large public displays,” Proc. 21st Annual Conference of the Australian Computer-Human Interaction Special Interest Group: Design: Open 24/7, 2009, pp. 161–168, doi:10.1145/1738826.1738853
- [14] R. Ballagas, M. Rohs, and J. G. Sheridan, “Sweep and point and shoot: phonecam-based interactions for large public displays,” Proc. HCI ’05 Extended Abstracts on Human Factors in Computing Systems, 2005, pp. 1200–1203, doi:10.1145/1056808.1056876
- [15] R. Hardy and E. Rukzio, “Touch & Interact: touch-based interaction of mobile phones with displays,” Proc. 10th International Conference on Human Computer Interaction with Mobile Devices and Services, 2008, pp. 245–254, doi:10.1145/1409240.1409267
- [16] A. Jameson, “More than the sum of its members: challenges for group recommender systems,” Proc. Working conference on Advanced visual interfaces, 2004, pp. 48–54, doi:10.1145/989863.989869
- [17] J. Masthoff, “Group modeling: selecting a sequence of television items to suit a group of viewers,” User Model User-Adapt. Interact., vol. 14, Feb. 2004, pp. 37–85, doi:10.1023/B:USER.0000010138.79319.fd
- [18] M. O’Connor, D. Cosley, J. A. Konstan, and J. Riedl, “PolyLens: a recommender system for groups of users,” in ECSCW 2001, W. Prinz, M. Jarke, Y. Rogers, K. Schmidt, and V. Wulf, Eds. Springer Netherlands, pp. 199–218, 2002.
- [19] J. K. Kim, H. K. Kim, H. Y. Oh, and Y. U. Ryu, “A group recommendation system for online communities,” in International Journal of Information Management., vol. 30, no. 3, Jun. 2010, pp. 212–219, doi:10.1016/j.ijinfomgt.2009.09.006
- [20] I. A. Christensen and S. Schiaffino, “Entertainment recommender systems for group of users,” Expert Systems with Applications, vol. 38, no. 11, Oct. 2011, pp. 14127–14135, doi:10.1016/j.eswa.2011.04.221
- [21] B. D. Carolis, “Adapting News and Advertisements to Groups,” in Pervasive Advertising, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, pp. 227–246, 2011
- [22] Apache, “Apache Mahout: Scalable machine learning and data mining.” Available: <http://mahout.apache.org/>, [Accessed: 05-Jul-2013].
- [23] Samsung, “Samsung Smart TV Apps Developer Forum,” Available: <http://www.samsungforum.com/Devtools/Spec>, [Accessed: 31-Jan-2014].
- [24] UPnP Forum, “UPnP Forum,” Available: <http://www.upnp.org/>, [Accessed: 11-Feb-2014].
- [25] UPnP Forum, “Universal Plug and Play Device Architecture,” Available: <http://upnp.org/specs/arch/UPnP-DeviceArchitecture-v1.1.pdf>, [Accessed: 11-Feb-2014].
- [26] S. Wellek, Testing Statistical Hypotheses of Equivalence, 1st ed., Chapman and Hall/CRC: Florida, 2002.

A.6. Anexo A6

A.6. Anexo A6

Enriching Public displays Ads Recommendations using an Individual – Group cooperation model

Francisco Martinez-Pabon
Telematics Engineering Group
University of Cauca
(+57 2) 8209800 ext. 2127
fomarti@unicauba.edu.co

Juan Camilo Ospina-Quintero
Telematics Engineering Group
University of Cauca
(+57 2) 8209800 ext. 2127
jcospina@unicauba.edu.co

Victor Garzon-Marin
Telematics Engineering Group
University of Cauca
(+57 2) 8209800 ext. 2127
vgarzon@unicauba.edu.co

Angela Chantre-Astaiza
GITUR Group
University of Cauca
(+57 2) 8209800 ext. 3120
achantre@unicauba.edu.co

Mario Muñoz-Organero
GAST Group
Carlos III University of Madrid
(+34) 916248801
mario.munoz@uc3m.es

Gustavo Ramirez-Gonzalez
Telematics Engineering Group
University of Cauca
(+57 2) 8209800 ext. 2127
gramirez@unicauba.edu.co

ABSTRACT

Ads recommendations delivery on digital signage environments must consider group and individual profiles. Although the ads recommendation precision is relevant and frequently explored, a good serendipity/precision balance must be a concern on Digital Signage context. This paper introduces a public display recommender system approach based on an individual-group cooperation model implemented throughout a Smart TV – Smartphone interaction scheme.

Categories and Subject Descriptors

H.5.1 [Information interfaces and presentation]: Multimedia Information Systems – evaluation/methodology. H.5.3 [Information interfaces and presentation]: Group and organization interfaces – Asynchronous interaction, computer-supported cooperative work.

General Terms

Algorithms, Design, Experimentation.

Keywords

Recommender systems, Pervasive advertising, Aggregation techniques, Digital signage.

1. INTRODUCTION

Although several approaches have been designed to deliver advertisements to potential clients throughout their personal devices (Smartphones, tablets or PC), even the public spaces are attractive taking into account that the 75% of the purchase decisions are taken at the sale places or near of them [1]; this

Permission to make digital or hard copies of part or all of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for third-party components of this work must be honored. For all other uses, contact the Owner/Author. Copyright is held by the owner/author(s).

PerDis '14, Jun 03-04 2014, Copenhagen, Denmark
ACM 978-1-4503-2952-1/14/06.
<http://dx.doi.org/10.1145/2611009.2617196>

field, known as Digital Signage, is related with digital content display using public screens [2]. Specifically, these spaces motivate the analysis of some issues: first, the ads must be addressed to a group of people, instead of individuals. On the other hand, the precision of the recommendations is a metric frequently evaluated on Recommender Systems (RS) researches, but the extent of serendipity is also important on the advertising domains as part of the persuasion; so, a balance between precision and serendipity is a desirable feature. Although some researches have proposed some alternatives to group recommendations [3] and/or public screens interaction schemes, [4] the research about a Public Screen – Smartphone cooperation model from a precision/serendipity balance perspective for advertising purposes is still incipient. This paper proposes a public display RS approach for digital signage environments based on an individual-group cooperation model implemented throughout a Smart TV – Smartphone interaction scheme. The experimentation results show the evaluation of some aggregation techniques for group recommendations according to precision and serendipity considerations.

2. PUBLIC DISPLAY RECOMMENDER SYSTEM ARCHITECTURE

The reference architecture for the model implementation is shown in Figure 1. Traditionally, the digital signage spaces use public displays with static information using a broadcast approach or some interaction approaches using mobile devices, but they do not use a multi-screen paradigm, so the smartphone or tablet screen is not fully functional. This model proposes a Smart TV – Smartphone cooperation scheme, so the Smart TV behaves as a public screen displaying recommendations for the group of users that are in front of the TV as long as the Smartphone screen is used to display ads according to the preferences of each user. Using this scheme, it is expected more precision for the ads in the Smartphone but also an interesting bigger extent of serendipity for recommendations on the TV screen, because the aggregation techniques will try to satisfy the preferences of a group of users by averaging individual preferences, which may not be accurate recommendations for each user, but they may result on novel ads instead, something valuable for pervasive advertising environments.

3. EXPERIMENTAL FRAMEWORK

An experimental framework was designed to make an evaluation about the behavior of some aggregation techniques for recommendation purposes in a group-individual cooperation model, and also to evaluate the extent of serendipity introduced by this model. This framework was based on the proposal of [5].

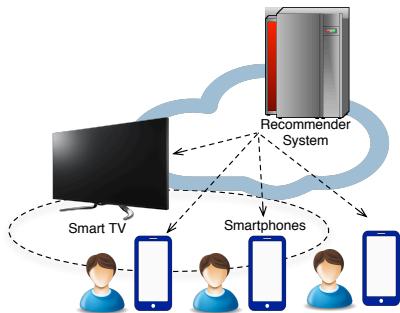


Figure 1 General architecture

A dataset with information about products and services ads was developed for testing the RS performance on a pervasive advertising environment with real users. At a first stage, a group of 26 students from the Tourism program of University of Cauca, post items and rate almost all of them using an alternative system without interacting with the Smart TV and Smartphone cooperation framework at all. The objective of this first phase was to build a low sparse and editable dataset to make offline tests about the performance of some RS algorithms as a previous step to group aggregation techniques evaluation; during the experiment, Spearman correlation showed a better performance according to Precision, Recall and ROC curves (Figure 2). In a second phase, a group of 49 students (21 men and 28 women ranging between 20 and 24 years old) post and rate items using the Smart TV and Smartphone cooperation framework (online tests). At the end, 137 items and 2190 ratings were considered for dataset using a scale from 1 to 5 for ratings.

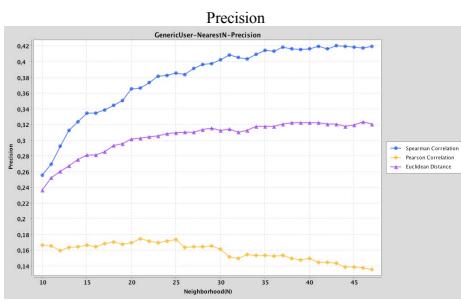


Figure 2 Precision metrics

From the Masthoff work [6], three group aggregation techniques were selected for evaluation, according to its convenience on this pervasive advertising environment: Less Misery, Most Pleasure and Additive. Each of these strategies was evaluated using the user-user similarity algorithm selected on the previous offline tests, with the aim to find out about the perceived serendipity from users; a Two-sample t technique was used to perform statistical analysis.

By and large, people perceived the ads on the Smart TV screen more novel than personalized ads on the phone according to the final survey results. In summary, Less misery technique offered a

best novelty value for users. The explanation may be related to the nature of the aggregation technique itself: as long as less misery looks for “all users satisfaction”, it is possible that other techniques like Most Pleasure offers some very interesting items for a user but they are less attractive to the others, which affects not only the accuracy but also the serendipity; useless items can not be considered novel, so a balance between accuracy and serendipity is important. Previous arguments may be supported by the analysis of the perceived user satisfaction where the Less Misery technique offered better results again.

4. CONCLUSIONS AND FUTURE WORK

One contribution of this paper has been to propose an approach for public display RS implementation on digital signage environments, using an individual-group cooperation model in order to keep the precision of recommended ads using a Smartphone screen but also improving the perceived serendipity throughout a group profile recommendations approach displayed on the Smart TV. Less misery technique demonstrated a better performance than other aggregation techniques regarding to perceived serendipity and satisfaction by the users, which means a better precision/serendipity balance for the pervasive advertisement research purposes. Further work is related with a deeper analysis for the aggregation techniques, with the aim of including contextual information.

5. ACKNOWLEDGMENTS

This work was supported by the University of Cauca throughout the projects VRI 3593 “SMARTA: Modelo para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone” and VRI 4045 “MANTIIS: Modelo para la adaptación de contenidos publicitarios en entornos n-screen interactivos soportados en un esquema de colaboración Smart TV – Smartphone”. Francisco Martínez is funded by Colciencias Doctoral scholarship N. 567.

6. REFERENCES

- [1] C. Bauer and S. Spiekermann, “Conceptualizing Context for Pervasive Advertising,” in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 159–183.
- [2] U. Stalder, “Digital Out-of-Home Media: Means and Effects of Digital Media in Public Space,” in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 31–56.
- [3] B. D. Carolis, “Adapting News and Advertisements to Groups,” in *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, 2011, pp. 227–246.
- [4] P. Santos, F. R. Ribeiro, and J. Metrolho, “Using pervasive computing technologies to deliver personal and public ads in public spaces,” in *2012 7th Iberian Conference on Information Systems and Technologies (CISTI)*, 2012, pp. 1–6.
- [5] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” *ACM Trans Inf Syst*, vol. 22, no. 1, pp. 5–53, Jan. 2004.
- [6] J. Masthoff, “Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers,” *User Model User-Adapt. Interact.*, vol. 14, no. 1, pp. 37–85, Feb. 2004.

A.7. Anexo A7

A.7. Anexo A7

Sistema de recomendaciones para entornos de Digital Signage soportado en un esquema de cooperación smart tv-smartphone

*Francisco Martínez-Pabón**
*Víctor Garzón-Marín***
*Juan Camilo Ospina-Quintero****
*Jhon Jairo Ibarra-Samboni*****
*Jaime Caicedo-Guerrero******
*Ángela Chantre-Astaiza******
*Gustavo Ramírez-González******

Recibido: 18/10/2013 • Aceptado: 17/01/2014

Resumen

La publicidad en entornos de *Digital Signage* demanda el enriquecimiento de la aproximación clásica de recomendación orientada a individuos, a través de la entrega de anuncios para un grupo de personas que observa una pantalla pública. Aunque la precisión que se pueda lograr en las recomendaciones es importante, lo es aún más el grado de novedad que puedan percibir los usuarios. Este balance puede obtenerse no solo a través de la mejora de los algoritmos de recomendación, sino también a través de un adecuado esquema de cooperación multi-pantalla. En este sentido, el presente artículo propone una aproximación para la construcción de un sistema de recomendaciones para entornos de *Digital Signage* soportado en un esquema de cooperación *Smart TV–Smartphone*.

Palabras clave: sistemas de recomendaciones, publicidad ubicua, técnicas de agregación, *digital signage*, *Smart TV*

-
- * PhD(c) en Ingeniería Telemática. Investigador Grupo de Ingeniería Telemática, Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70, Tel: (57 2) 8209800 ext. 2127, email: fomarti@unicauca.edu.co.
- ** Ing. en Electrónica y Telecomunicaciones. Investigador Grupo de Ingeniería Telemática, Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70, Tel: (57 2) 8209800 ext. 2127, email: vgarzon@unicauca.edu.co.
- *** Ing. en Electrónica y Telecomunicaciones. Investigador Grupo de Ingeniería Telemática, Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70, Tel: (57 2) 8209800 ext. 2127, email: jcospina@unicauca.edu.co.
- **** Ing. en Electrónica y Telecomunicaciones. Investigador Grupo de Ingeniería Telemática, Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70, Tel: (57 2) 8209800 ext. 2127, email: jjibarra@unicauca.edu.co.
- ***** Ing. en Electrónica y Telecomunicaciones. Investigador Grupo de Ingeniería Telemática, Docente Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70 Oficina 405, Tel: (57 2) 8209800 ext. 2127, email: jcaicedo@unicauca.edu.co.
- ***** Magíster en Marketing. Profesora de Planta Departamento de Ciencias del Turismo, Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70, Tel: (57 2) 8209800 ext. 2127, email: achantre@unicauca.edu.co.
- ***** PhD. en Ingeniería Telemática. Profesor de Planta Departamento de Telemática, Universidad del Cauca, Popayán, Colombia. Calle 5 # 4 -70, Tel: (57 2) 8209800 ext. 2127, email: gramirez@unicauca.edu.co.

Recommendations system for Digital Signage environments based on a smart tv-smartphone cooperation scheme

Abstract

Advertisement in Digital Signage environments demands the enrichment of the classic approach of recommendation focused on individuals by means of the delivery of ads for a group of people observing a public screen. Even though the accuracy that can be achieved in the recommendations is important, the degree of novelty perceived by the users is even more important. This balance can be obtained not only through the improvement of the recommendation algorithms, but also through an adequate multi-screen cooperation scheme. Therefore, this paper proposes an approach for the construction of a recommendations system for Digital Signage environments based on a Smart TV-Smartphone cooperation scheme.

Keywords: recommendations systems, ubiquitous advertising, aggregation techniques, digital signage, Smart TV.

INTRODUCCIÓN

La publicidad juega un papel transcendental en el comercio moderno, al punto que grandes compañías como Google obtienen importantes ingresos a partir de contenido publicitario. Específicamente la publicidad es parte de la promoción, una de las áreas del *marketing*, y es definida como “cualquier forma remunerada de presentación y promoción no personal de ideas, bienes o servicios por parte de un *sponsor* identificado” [1]. Actualmente, un nuevo paradigma conocido como publicidad ubicua, el cual se refiere al uso de tecnologías de computación ubicua con fines publicitarios [1], ha surgido como una interesante promesa para consumidores y anunciantes.

Pese a que la mayoría de las aproximaciones en este contexto han sido concebidas para dirigir los anuncios a los dispositivos personales de los usuarios (*Smartphones*, *tablets*, *PC*), aún los espacios públicos resultan muy interesantes para la industria, teniendo en cuenta que el 75 % de las decisiones de compra se toma en los propios lugares de venta o cerca de ellos [2]; este campo, conocido como *Digital Signage*, hace referencia al despliegue de contenido digital a través de pantallas públicas [3]. Tradicionalmente, el talón de Aquiles de la publicidad ha sido la falta de contenido personalizado para los usuarios, especialmente en entornos de *Digital Signage*, donde la entrega de anuncios sigue una filosofía *broadcast*, convirtiéndose así en uno de los principales desafíos para la publicidad ubicua. En este contexto, los sistemas de recomendaciones (SR) surgen como una poderosa alternativa; este tipo de sistemas aplican técnicas de búsqueda y filtrado de información para proporcionar a los usuarios sugerencias personalizadas sobre un conjunto de ítems en un dominio específico [4].

No obstante, la entrega de recomendaciones en ambientes de *Digital Signage* conlleva el análisis de algunas consideraciones. En primer lugar, los anuncios deben ir dirigidos a un grupo de personas que están observando la pantalla, más que a individuos en particular; por otro lado, la precisión de las recomendaciones es una métrica que rige frecuentemente la evaluación de este tipo de sistemas, pero en los entornos publicitarios el grado de novedad que se introduce a través de la recomendación puede ser tan o más importante que la precisión misma, con fines de persuasión.

El presente trabajo propone una aproximación para la construcción de un sistema de recomendaciones en un entorno de *Digital Signage*, soportado en un esquema de cooperación *Smart TV–Smartphone*; la fase de experimentación se concentra en la evaluación de algunas técnicas de recomendación grupal, de acuerdo con parámetros de novedad y precisión. De acuerdo con lo anterior, el artículo se desarrolla a partir de la siguiente estructura: en la sección 1 se presentan algunos trabajos relacionados; la sección 2 describe brevemente la arquitectura de referencia propuesta; la sección 3 resume los resultados experimentales, que son discutidos posteriormente en la sección 4. Finalmente se presentan algunas conclusiones.

1. ESTADO DEL ARTE

A medida que los entornos de computación ubicua evolucionan, surgen muchos campos de aplicación atractivos y, sin lugar a dudas, la publicidad ubicua es uno de ellos. Como fue discutido previamente, la personalización es uno de los aspectos clave en este tipo de ambientes, y en ese sentido los SR constituyen una poderosa herramienta para enfrentar este desafío. Estos sistemas han sido estudiados durante las últimas dos décadas y tradicionalmente se han considerado tres técnicas para su implementación: el filtrado colaborativo es probablemente la alternativa más usada, y consiste en computar correlaciones entre usuarios a través del reconocimiento de su afinidad en preferencias y *ratings* otorgados sobre un conjunto de ítems con anterioridad; por otro lado, los sistemas basados en contenido, parten del comportamiento histórico del usuario, utilizando sus preferencias para predecir *ratings* sobre ítems, de acuerdo con la similitud que éstos guardan con otros ítems calificados en el pasado; finalmente, los sistemas híbridos combinan dos o más técnicas para mejorar el funcionamiento del SR. En este sentido, algunos trabajos resumen los principales conceptos, algoritmos y técnicas relacionadas con este campo [5-6]. No obstante, de acuerdo con [4] “el desarrollador de un SR para un dominio de aplicación específico debería entender las diferentes características del mismo, sus requerimientos, desafíos de aplicación y limitaciones”, lo cual evidencia la importancia del dominio de aplicación para sentar las bases de cualquier tipo de investigación en esta área. En consecuencia, algunos trabajos han dado los primeros pasos para caracterizar dominios de publicidad ubicua, incluyendo sus características, desafíos y algunas tecnologías clave [7-8].

Por otro lado, como fue mencionado anteriormente, dos aspectos merecen ser analizados desde la perspectiva de los entornos de *Digital Signage*: recomendaciones para grupos de individuos y el balance precisión/novedad. Con respecto al primero, algunas aproximaciones han sido desarrolladas para la generación de recomendaciones grupales: [9] analiza diferentes aspectos relacionados con las recomendaciones para grupos, y [10] discute algunas estrategias conocidas como técnicas de agregación, las cuales tratan de consolidar un promedio a partir de preferencias individuales con miras a la definición de un modelo grupal para la entrega de recomendaciones. Otros sistemas relacionados con esta aproximación como *PolyLens* [11], una versión especializada de *MovieLens*, recomienda películas usando un algoritmo que combina listas de recomendación para usuarios individuales y las organiza en orden decreciente; *MusicFX* [12], por su parte, recomienda canciones para grupos de usuarios usando una suma normalizada de calificaciones recibidas para todos los ítems de la lista. Por otro lado, *Intrigue* [13] soporta la configuración de planes turísticos para grupos heterogéneos de usuarios a partir de modelos de preferencias de sub-grupos homogéneos de usuarios, mientras que [14] desarrolló una propuesta para ambientes de publicidad

ubicua usando una aproximación de agregación para recomendar anuncios a grupos de personas en un gimnasio; los anuncios son desplegados en una pantalla pública y en dispositivos móviles, pero básicamente son replicados, y no existe un mecanismo de interacción entre ellos. Además, solo se consideró una técnica de agregación aditiva durante la experimentación.

En otro sentido, con respecto al despliegue de anuncios en ambientes ubicuos, algunos autores han generado reflexiones sobre consideraciones relevantes para el diseño de entornos de *Digital Signage* [3]. Igualmente, otros trabajos han hecho énfasis en el despliegue de anuncios para dispositivos móviles usando algunos modelos de interacción entre pantallas con tecnologías como *Bluetooth* o *NFC* [15-16]. No obstante, un esquema multi-pantalla cooperativo, donde el contenido no se replique en cada despliegue sino que se especialice en cada dispositivo, es una característica deseable que aún ha sido poco explorada en entornos publicitarios. Aunque algunas aproximaciones han considerado escenarios *n-screen* [17], específicamente la investigación sobre el potencial de un esquema de cooperación *SmartTV–Smartphone* es aún incipiente.

2. ARQUITECTURA DEL SISTEMA DE RECOMENDACIONES PARA ENTORNOS DE DIGITAL SIGNAGE

La arquitectura de referencia para el sistema de recomendaciones propuesto se muestra en la figura 1. De acuerdo con el estado del arte, los espacios de *Digital Signage* tradicionales usan pantallas públicas con información estática siguiendo una filosofía eminentemente *broadcast*; aunque algunas aproximaciones usan dispositivos móviles para proporcionar algún grado de interactividad, realmente no se considera un paradigma cooperativo multi-pantalla (*n-screen*) como tal, así que de alguna manera se termina desperdiando la capacidad de las pantallas de los *Smartphones* o las *Tablets*.

En estos términos, la arquitectura propuesta considera un esquema de cooperación *Smart TV–Smartphone*, de tal manera que la pantalla del televisor se comporta como una pantalla pública que recomienda anuncios para el grupo de personas que se encuentra frente a la misma, al tiempo que la pantalla de cada uno de los *Smartphones* despliega anuncios con un carácter más personalizado para cada uno de los usuarios. La hipótesis sobre la cual se soporta el planteamiento de este esquema es que los anuncios desplegados en los *Smartphones* tendrán un mayor grado de precisión que los anuncios grupales, lo cual es un factor que potencia el despliegue de anuncios novedosos a través de la pantalla pública. Al tratar de generar recomendaciones para un grupo de personas, las técnicas de agregación no serán suficientemente precisas para cada usuario en particular, pero en cambio pueden generar un conjunto de anuncios desconocidos y novedosos cuando las personas observan pantalla pública, algo valioso para entornos de publicidad ubicua con fines de persuasión.

En consecuencia, se ha proporcionado una implementación de referencia para la arquitectura propuesta usando el *framework Apache Mahout* [18] para el SR, el *SDK* de *Samsung* para el *Smart TV* [19] y la plataforma *Android* para la aplicación móvil. Igualmente, se ha desarrollado un *API* estilo *REST* para habilitar la comunicación entre el SR, el Smart TV y los Smartphones, al tiempo que un protocolo basado en *UPnP* fue implementado para soportar la colaboración *Smart TV–Smartphone*. Como una breve descripción del protocolo, la figura 2 muestra un diagrama de flujo simple relacionado con el proceso de descubrimiento entre los teléfonos y el Smart TV, y la tabla 1 muestra la estructura de un mensaje para publicar anuncios en la pantalla del TV desde el móvil.

Tabla 1. Estructura del mensaje para publicar anuncios en la pantalla del TV desde el Smartphone.

Ad post message request		
Source-destination	Smartphone-Smart TV	
Type	HTTP POST	
Path	http://TV_IPADDR/ws/app/SMARTA/connect	
Path parameters	TV_IPADDR: Smart TV IP address	
HTTP Headers	SLDeviceID	Random sequence of 10 alphabetic characters
	ProductID	SMARTDev
	VendorID	VendorMe
	msgNumber	Auto incremental sequence number for the message
	Content-Type	application/json
	Connection	Keep-Alive
	Accept	/*
	Accept-Encoding	gzip, deflate, sdch
	Accept-Language	es,en-US;q=0.8,en;q=0.6
	Transfer-Encoding	chunked
	Content-Length	Number of sent bytes in JSON format
Content	<pre>{ "type": "post", "title": "ttt", "content": "cccc", "img_url": "uuu" }</pre>	

Ad post message reply		
Reply codes	200	Accepted connection
	403	Not authorized to receive messages.
	404	Unknown APP_ID.
Reply content	<pre>{ "type": "post", "posted": "true/false" }</pre>	

Fuente: autores

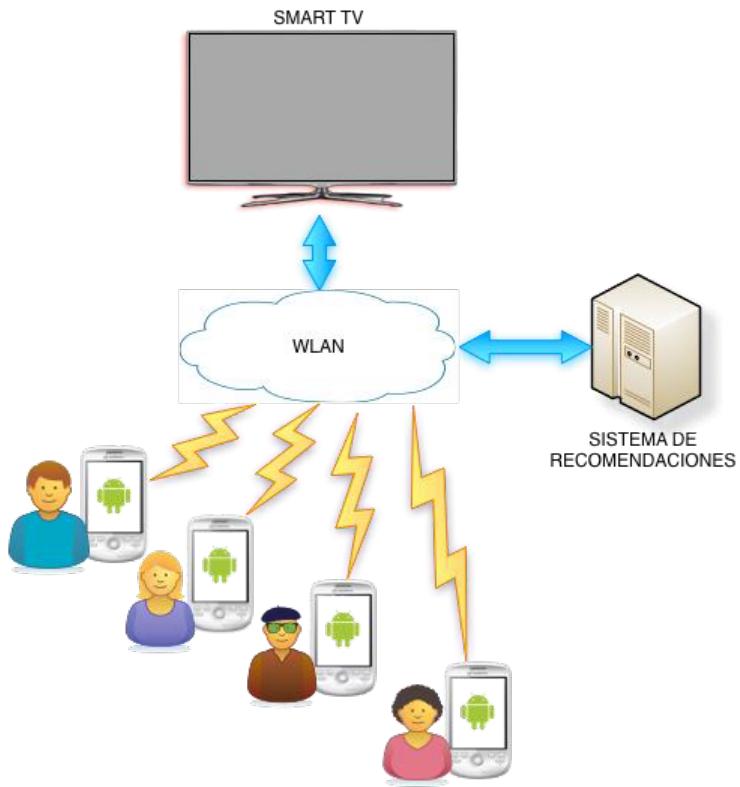


Figura 1. Arquitectura del sistema de recomendaciones con soporte Smart TV-Smartphone.

Fuente: autores

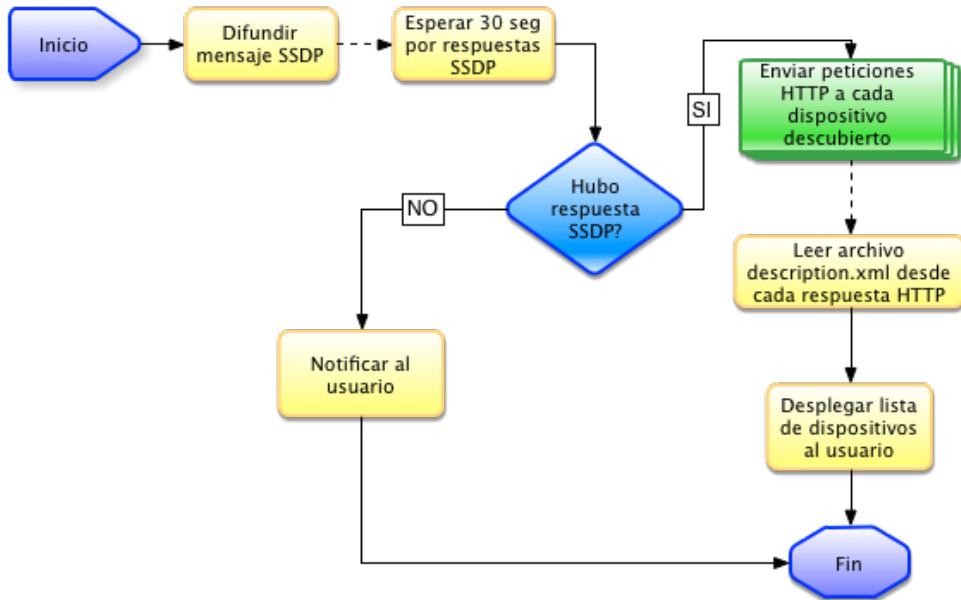


Figura 2. Proceso de descubrimiento Smart TV–Smartphone.

Fuente: autores

Tomando como base esta implementación de referencia, se ha construido un prototipo que incluye las siguientes funcionalidades: i) recomendaciones para grupos de usuarios usando técnicas de agregación; ii) recomendaciones para individuos de acuerdo con preferencias personales; iii) despliegue de recomendaciones grupales en la pantalla del televisor y recomendaciones individuales en la pantalla de los *Smartphones*; iv) interacción *Smart TV–Smartphone* para seleccionar un anuncio grupal en la pantalla del *TV* y detallar su información en la pantalla del teléfono o publicar anuncios en el *TV* desde el teléfono móvil. La figura 3 muestra algunas interfaces del prototipo construido.



Figura 3. Interfaces del prototipo construido.

Fuente: autores

3. RESULTADOS

Con el ánimo de comprobar la hipótesis que sustenta el planteamiento de la arquitectura propuesta, se diseñó un marco experimental que busca evaluar el comportamiento de algunas técnicas de agregación en un contexto de *Digital Signage* e igualmente determinar el grado de novedad introducido, gracias a la incorporación de un esquema multi-pantalla. Este marco experimental está basado en la propuesta de [20].

4. CONSIDERACIONES SOBRE EL DOMINIO

Durante el experimento, se simuló un entorno de *Digital Signage* en un ambiente académico a través de la implementación de una cartelera electrónica de anuncios

publicitarios, una herramienta muy popular en los campus universitarios, utilizando un esquema de interacción *SmartTV–Smartphone*. Por consiguiente, algunas características del dominio publicitario fueron consideradas para el diseño del experimento: la tarea principal del SR será recomendar “algunos buenos ítems”; no “todos los buenos ítems” son requeridos para propósitos publicitarios, y la maximización de la utilidad para el usuario está relacionada no solo con una buena precisión sino también con el grado de novedad introducido; incluso, en la mayoría de los casos la introducción de novedad puede ser más importante que la precisión para este contexto.

En consecuencia, aunque la tasa de falsos positivos entregada por el SR podría considerarse publicidad *spam*, algunos de estos anuncios podrían resultar novedosos; luego un balance entre precisión/novedad es una característica deseable. Por otro lado, la tasa de falsos negativos es particularmente relevante para los anunciantes, teniendo en cuenta sus intereses acerca de la recomendación de anuncios que se consideran importantes para sus propósitos.

5. CONSIDERACIONES SOBRE EL DATASET

Se construyó un *dataset* con información de anuncios de productos y servicios para evaluar el funcionamiento del SR en un entorno real a partir de la interacción con los usuarios. En una primera fase, un grupo de 26 estudiantes del programa de Turismo de la Universidad del Cauca incluyeron anuncios, y calificaron la mayoría de ellos usando un sistema alterno, aún sin interactuar a través del esquema *Smart TV–Smartphone*; el objetivo principal era construir un *dataset* editable y con baja dispersión para realizar pruebas *offline* (sin usuarios reales) sobre algunos algoritmos de recomendación, como paso previo a la evaluación de las técnicas de agregación de carácter grupal.

En una segunda fase, los *tests online* (con usuarios reales) incluyeron un grupo de 49 estudiantes, 21 hombres y 28 mujeres en un rango de edades entre 20 y 24 años, los cuales agregaron anuncios y calificaron algunos de ellos accediendo al *SR* a través de la arquitectura *Smart TV–Smartphone* propuesta. Al final se obtuvieron 137 anuncios publicitarios y 2190 *ratings* para el *dataset* en una escala de 1 a 5. A continuación se describirán en más detalle los aspectos considerados para las pruebas *offline* y *online*.

6. PRUEBAS OFFLINE

Las pruebas *offline* fueron diseñadas para evaluar el funcionamiento de algunos algoritmos de recomendación, particularmente técnicas de similitud siguiendo una aproximación colaborativa usuario–usuario, con el objeto de seleccionar el algoritmo con el mejor comportamiento de acuerdo con las características del dominio particular y el *dataset* construido. Durante esta fase, se hizo énfasis en la utilización de métri-

cas de precisión sobre tres técnicas de similitud específicas: correlación de *Pearson*, correlación de *Spearman* y distancia euclíadiana. Las métricas utilizadas para evaluar los diferentes algoritmos fueron RMSE (*Root Mean Square Error*), precision, recall y las curvas ROC (tabla 2). De acuerdo con los resultados obtenidos, aunque la distancia euclíadiana demostró un mejor RMSE que las correlaciones de *Pearson* y *Spearman*, la correlación de *Spearman* mostró un mejor comportamiento de acuerdo con el análisis de las curvas de precisión, *recall* y *ROC* (Ver figura 4), razón por la cual es seleccionada como técnica de filtrado. Por otro lado, aunque el uso de la correlación de *Spearman* supone un costo computacional más alto que el de las otras técnicas, dado que ordena los ratings y les da una calificación previamente al cálculo de la similitud, se utilizó un mecanismo de caché disponible en *Mahout* para evitar recalcular valores de similitud previamente procesados.

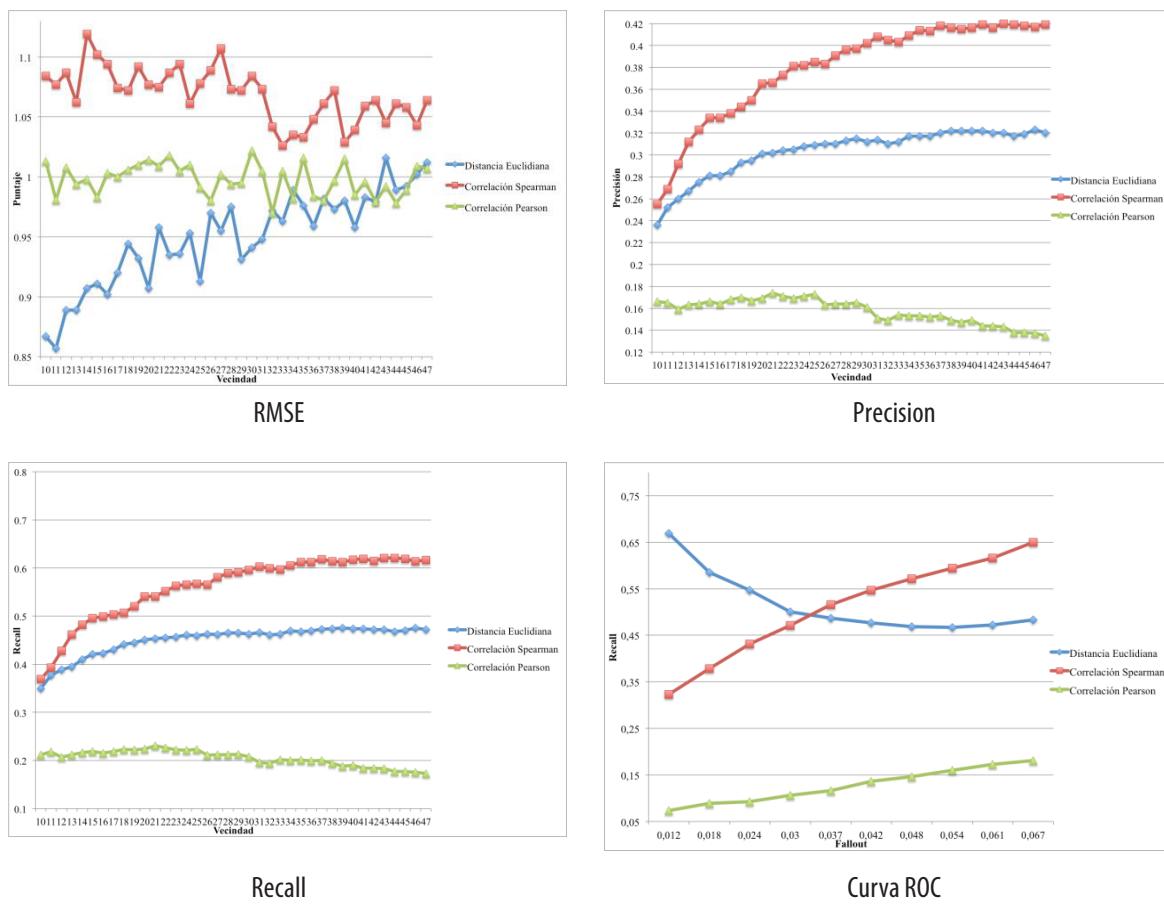


Figura 4. Curvas de precisión, recall y ROC para las pruebas offline.

Fuente: autores

Tabla 2. Métricas de evaluación para las técnicas de filtrado colaborativo.

Tarea	Métrica	Meta
Predicción	RMSE	Calcula la desviación entre el rating que se predice y el rating real (MAE); posteriormente este resultado se eleva al cuadrado para dar más peso a los errores de mayor magnitud.
Recomendación	Precision	Probabilidad de que un ítem seleccionado sea relevante.
	Recall	Probabilidad de que un ítem relevante sea seleccionado.
	Curvas ROC	Hacen énfasis en calcular la proporción de ítems que no son relevantes y que finalmente son recomendados.

Fuente: Herlocker, et.al [5]

7. PRUEBAS ONLINE

Luego de la consolidación de los resultados de las pruebas *offline*, se realizó el montaje de un entorno de *Digital Signage* simulado en un espacio académico, usando el esquema de interacción *Smart TV–Smartphone*. En una primera instancia, cada individuo calificó algunos anuncios seleccionados de forma aleatoria a través de una página *Web* alternativa, con el objeto de minimizar el problema de *cold start*, una deficiencia común en los SR que hace referencia a las restricciones del sistema para generar recomendaciones cuando no se tiene suficiente información disponible, algo frecuente en el caso de usuarios o ítems nuevos.

Posteriormente, se configuraron aleatoriamente grupos de cuatro personas para interactuar con el *Smart TV* usando la aplicación *Android* en el *Smartphone* durante un período de aproximadamente 5 minutos. Al final, cada usuario llenó una encuesta en la cual se indagó directamente sobre el grado de novedad y precisión percibido por cada uno de los participantes con respecto a las recomendaciones entregadas tanto por el Smart TV como por el Smartphone.

Específicamente, los *tests* realizados consideraron la evaluación de tres técnicas de agregación seleccionadas a partir del trabajo de Masthoff [10], de acuerdo con su conveniencia y grado de aplicación en entornos publicitarios; la tabla 3 resume las definiciones de las técnicas empleadas. En este sentido, cada una de las estrategias de agregación fue sometida a prueba usando el algoritmo de similitud usuario-usUARIO seleccionado durante la fase de pruebas *offline*. De acuerdo con los resultados, en términos generales se puede concluir que las personas percibieron mayor novedad en los anuncios desplegados en la pantalla del *Smart TV*, como era de esperarse de acuerdo con el planteamiento de la hipótesis. No obstante, un análisis más profundo será presentado en la siguiente sección con el objeto de aclarar detalles del comportamiento de las técnicas de agregación consideradas.

Tabla 3. Descripción de las técnicas de agregación grupal.

Test No.	Técnica de agregación	Descripción
1	Aditiva	Los ratings son adicionados. Los valores de suma mayores configuran la lista de recomendación.
2	Mínima miseria	Hace una lista de los ratings con el mínimo de los ratings individuales; los ítems son recomendados de acuerdo a los ratings de la lista, el más alto primero. El grupo están tan satisfecho como su miembro menos satisfecho.
3	Máximo beneficio	Hace una lista de los ratings con el máximo de los ratings individuales; los ítems son recomendados de acuerdo a los ratings de la lista, el más alto primero

Fuente: Masthoff [10]

8. DISCUSIÓN

La tabla 4 resume algunos resultados estadísticos con respecto a la novedad percibida por los usuarios para cada una de las técnicas de agregación. El valor de la media sugiere que la técnica de “Mínima miseria” ofrece un mejor comportamiento con respecto a la novedad percibida. Sin embargo, es importante averiguar si esta diferencia es significativa, dado que la evaluación se llevó a cabo para muestras de usuarios diferentes; en otras palabras, el propósito es determinar si el grado de novedad percibida usando la técnica de “mínima miseria” es significativamente mayor con respecto a la técnica “aditiva” o de “máximo beneficio”. Para soportar este análisis, se hizo uso de la técnica estadística *two sample t*, de acuerdo con los siguientes lineamientos: se debe considerar una hipótesis nula durante la prueba; en este caso, existen dos hipótesis nulas; la primera de las cuales propone que la novedad percibida a partir del uso de la técnica aditiva es la misma con respecto a la técnica de mínima miseria; en los mismos términos, la segunda hipótesis involucra las técnicas de mínima miseria y máximo beneficio. En ambos casos, se considera una hipótesis alternativa, la cual propone que la estrategia de mínima miseria ofrece un mayor grado de novedad percibida. La tabla 5 muestra los resultados del análisis para ambas hipótesis tomando como base un valor p de 5 %; en este sentido, un valor de p por debajo de 0,05 es una evidencia estadística que aprueba la hipótesis alternativa sobre cualquiera de las hipótesis nulas.

Tabla 4. Nivel de novedad percibido (pruebas online).

Técnica de agregación	Tamaño de muestra	Media	Desviación estándar
Additive	16	$u_A = 3,438$	1,209
Less misery	18	$u_{LM} = 3,944$	0,802
Most pleasure	14	$u_{MP} = 3,214$	0,699

Fuente: autores

Tabla 5. Resultados de la prueba 2 sample t para novedad percibida.

<i>Test</i>	<i>Hipótesis nula</i>	<i>Hipótesis alternativa</i>	<i>Valor p</i>
1	$uLM = uA$	$uLM > uA$	0,084
2	$uLM = uMP$	$uLM > uMP$	0,005

Fuente: autores

De acuerdo con lo anterior, aunque no fue posible concluir si existe una diferencia contundentemente significativa sobre la estrategia aditiva, es claro que el grado de novedad percibido a través de la estrategia de mínima miseria es mayor que el que se logra a través de la técnica de máximo beneficio. La explicación puede estar relacionada con la naturaleza misma del funcionamiento de las técnicas: mientras la técnica de mínima miseria busca de alguna manera la satisfacción de “todos los usuarios”, es posible que la estrategia de “máximo beneficio” ofrezca algunos anuncios interesantes para un usuario en particular, pero estos resultan poco o nada atractivos para otros individuos, lo cual afecta la precisión pero también la novedad percibida. Los anuncios inútiles no pueden considerarse necesariamente novedosos, así que debe buscarse un balance entre novedad y precisión.

En consecuencia, los argumentos anteriores se pueden soportar a través de un análisis similar con respecto a la satisfacción percibida. Como se puede observar en las tablas 6 y 7, en ambos experimentos los valores obtenidos para p fueron inferiores a 0,05, lo cual significa que hay una diferencia significativa en la satisfacción percibida por los usuarios cuando se emplea la técnica de mínima miseria sobre cualquiera de las otras dos estrategias; luego se logra un mejor balance novedad/precisión.

Tabla 6. Nivel de satisfacción percibido (pruebas online).

<i>Técnica de agregación</i>	<i>Tamaño de muestra</i>	<i>Media</i>	<i>Desviación estándar</i>
Additive	16	$uA = 3,375$	0,957
Less misery	18	$uLM = 4,056$	0,725
Most pleasure	14	$uMP = 3,5$	0,941

Fuente: autores

Tabla 7. Resultados de la prueba 2 sample t para satisfacción percibida.

<i>Test</i>	<i>Hipótesis nula</i>	<i>Hipótesis alternativa</i>	<i>Valor p</i>
1	$uLM = uA$	$uLM > uA$	0,014
2	$uLM = uMP$	$uLM > uMP$	0,040

Fuente: autores

9. CONCLUSIONES

Una de las principales contribuciones de este trabajo es la definición de una aproximación para generar recomendaciones de anuncios en un entorno de *Digital Signage*, no solo abordando una mejora en los algoritmos de recomendación como tradicionalmente se ha hecho en las investigaciones de este tipo, sino apoyando el trabajo de los algoritmos para la entrega de los anuncios a través de un esquema de colaboración multi-pantalla *Smart TV – Smartphone*. Frecuentemente, la precisión de las recomendaciones ha sido una preocupación constante para los investigadores, pero el esquema propuesto favorece en su lugar un balance entre la precisión y la novedad de las mismas, algo indiscutiblemente valioso para un dominio de aplicación como la publicidad.

Por otro lado, las técnicas de agregación grupal de mínima miseria y máximo beneficio demostraron un mejor comportamiento que la estrategia aditiva con respecto a la novedad percibida por parte de los usuarios, pero la técnica de mínima miseria parece ofrecer un mayor grado de satisfacción, lo cual significa un mejor balance precisión/novedad para los propósitos de la investigación.

Finalmente, a manera de trabajo futuro se requiere un análisis más profundo del comportamiento de las técnicas de agregación con el ánimo de cuantificar el grado de novedad; adicionalmente, la inclusión de información contextual en los algoritmos de recomendación resulta interesante para los propósitos del dominio de aplicación.

AGRADECIMIENTOS

El presente trabajo fue soportado por la Universidad del Cauca a través de los proyectos VRI 3593 “SMARTA: Modelo para el despliegue de publicidad en entornos de computación ubicua soportado en un esquema de cooperación Smart TV - Smartphone” y VRI 4045 “MANTISS: Modelo para la adaptación de contenidos publicitarios en entornos n-screen interactivos soportados en un esquema de colaboración Smart TV - Smartphone”. Francisco Martínez cuenta con la financiación del programa de becas doctorales 2012 de Colciencias, convocatoria 567.

REFERENCIAS

- [1] J. Müller, F. Alt, and D. Michelis, “Pervasive Advertising,” en *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, eds., pp. 1–29, Springer London, 2011.
- [2] C. Bauer and S. Spiekermann, “Conceptualizing Context for Pervasive Advertising,” en *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, eds., pp. 159–183, Springer London, 2011.
- [3] U. Stalder, “Digital Out-of-Home Media: Means and Effects of Digital Media in Public Space,” en *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, eds. , pp. 31–56, Springer London, 2011.

- [4] F. Ricci, L. Rokach, and B. Shapira, “Introduction to Recommender Systems Handbook,” en Recommender Systems Handbook, F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, eds. , pp. 1–35, Springer US, 2011.
- [5] J. L. Herlocker, J. A. Konstan, A. Borchers, and J. Riedl, “An Algorithmic Framework for Performing Collaborative Filtering,” presentado en Proceedings of the 22Nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, New York, 1999.
- [6] Q. Li and B. M. Kim, “An approach for combining content-based and collaborative filters,” presentado en Proceedings of the sixth international workshop on Information retrieval with Asian languages - Volume 11, Stroudsburg, 2003,
- [7] K. Partridge and B. Begole, “Activity-Based Advertising,” en Pervasive Advertising, J. Müller, F. Alt, and D. Michelis, eds. , pp. 83–101, Springer London, 2011.
- [8] P. van Waart, I. Mulder, and C. de Bont, “Meaningful Advertising,” in Pervasive Advertising, J. Müller, F. Alt, and D. Michelis, eds., pp. 57–81 Springer London, 2011.
- [9] A. Jameson, “More than the sum of its members: challenges for group recommender systems,” presentado en Proceedings of the working conference on Advanced visual interfaces, New York, 2004.
- [10] J. Masthoff, “Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers,” User Model. User-Adapt. Interact., vol. 14, no. 1, pp. 37–85, 2004.
- [11] M. O’Connor, D. Cosley, J. A. Konstan, and J. Riedl, “PolyLens: A Recommender System for Groups of Users,” en ECSCW 2001, W. Prinz, M. Jarke, Y. Rogers, K. Schmidt, and V. Wulf, eds., pp 199–218, Springer Netherlands, 2002.
- [12] J. F. McCarthy and T. D. Anagnost, “MusicFX: an arbiter of group preferences for computer supported collaborative workouts,” presentado en Proceedings of the 1998 ACM conference on Computer supported cooperative work, New York, 1998.
- [13] L. Ardissono, A. Goy, G. Petrone, M. Segnan, and P. Torasso, “Intrigue: Personalized recommendation of tourist attractions for desktop and hand held devices,” Appl. Artif. Intell., vol. 17, no. 8–9, pp. 687–714, 2003.
- [14] B. D. Carolis, “Adapting News and Advertisements to Groups,” en Pervasive Advertising, J. Müller, F. Alt, and D. Michelis, eds. , pp. 227–246, Springer London, 2011.
- [15] R. Jose, N. Otero, S. Izadi, and R. Harper, “Instant Places: Using Bluetooth for Situated Interaction in Public Displays,” IEEE Pervasive Comput., vol. 7, no. 4, pp. 52–57, 2008.
- [16] J. Ibarra et al., *Integración de pizarras interactivas de bajo costo con un LMS. Propuesta para el caso .LRN – Universidad del Cauca*. USA: R&I Book, 2012, 208p.
- [17] P. Santos, F. R. Ribeiro, and J. Metrolho, “Using pervasive computing technologies to deliver personal and public ads in public spaces,” presentado en 2012 7th Iberian Conference on Information Systems and Technologies (CISTI), 2012.
- [18] Apache Mahout: Scalable machine learning and data mining. [En linea]. Acceso: 05 de Julio, 2013; Disponible: <http://mahout.apache.org/>

- [19] Samsung, Samsung Smart TV Apps Developer Forum. [En linea]. Acceso: 31 de Enero,2014; Disponible: <http://www.samsungforum.com/Devtools/Spec>.
- [20] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” ACM Trans Inf Syst, vol. 22, no. 1, pp. 5–53, 2004.

A.8. Anexo A8

A.8. Anexo A8

MODELO CONCEPTUAL PARA EL DESPLIEGUE DE PUBLICIDAD UBICUA SOPORTADO EN UN ESQUEMA DE COOPERACIÓN SMART TV - SMARTPHONE

CONCEPTUAL MODEL FOR PERVERSIVE ADVERTISING SUPPORTED ON A SMART TV - SMARTPHONE COOPERATION FRAMEWORK

Francisco Martínez-Pabón¹, Gustavo Ramírez-González², Ángela Chantre-Astaiza³

Fecha de recepción: 1 de agosto de 2013

Fecha de aprobación: 5 de marzo de 2014

Referencia: F. Martínez Pabón, G. Ramírez González, A. Chantre Astaiza. (2014). Modelo conceptual para el despliegue de publicidad ubicua soportado en un esquema de cooperación Smart TV – Smartphone. Ciencia e Ingeniería Neogranadina, 24 (1), pp. 116 - 142.

RESUMEN

La publicidad ha sido durante años una de las herramientas más valiosas del mercadeo a través de un enfoque principalmente masivo, generalizado y vertical entre clientes y anunciantes. No obstante, una nueva corriente conocida como publicidad ubicua marca una evolución en el concepto clásico hacia entornos más interactivos, personalizados y horizontales que busca mejorar la eficiencia y el impacto de la publicidad convencional. Gracias al apoyo de tecnologías emergentes que se sustentan en la evolución de los *Smartphones* y los *Smart TV*, el potencial de la publicidad ubicua es indudable, lo cual la ha convertido en un terreno fértil de investigación. El presente artículo presenta un modelo conceptual que condensa las áreas de investigación más relevantes relacionadas con el despliegue de publicidad en entornos de computación ubicua soportados en esquemas de cooperación *Smart TV – Smartphone*.

Palabras clave: publicidad ubicua, *Smart TV*, *Smartphone*

ABSTRACT

Advertising has been one of the most valuable marketing tools for years by means of a massive, wide-ranging and vertical approach between customers and advertisers. However, a new tendency known as pervasive advertising suggests an evolution of the

1. Ing. en Electrónica y Telecomunicaciones, mi grado profesional de MSc a PhD(c), Investigador Grupo de Ingeniería Telemática, fomarti@unicauca.edu.co, Universidad del Cauca, Popayán, Colombia.

2. Ing. en Electrónica y Telecomunicaciones, PhD., Profesor de planta, gramirez@unicauca.edu.co, Departamento de Telemática, Investigador Grupo de Ingeniería Telemática, Universidad del Cauca, Popayán, Colombia.

3. Administradora de Empresas, MSc, Investigadora Grupo de Desarrollo Turístico y Regional, achantre@unicauca.edu.co, Universidad del Cauca, Popayán, Colombia.

classical concept towards a more interactive, customized, and horizontal environment that seeks to improve the impact and efficiency of conventional advertising. As a result of the support of emerging technologies related to the development of Smartphones and Smart TVs, there are no doubts about pervasive advertising potential and its value as a rich research field. This article introduces a conceptual model, which compiles the most relevant research areas related to pervasive computing applied to advertising supported on a Smart TV – Smartphone cooperation framework.

Keywords: pervasive advertising, Smart TV, Smartphone.

INTRODUCCIÓN

Sin lugar a dudas, la publicidad juega un papel importante como motor del comercio moderno en cualquiera de sus modalidades, al punto que grandes compañías como Google impulsan gran parte de sus ingresos en el sustento de la publicidad. Frecuentemente, el concepto de publicidad se confunde con el concepto de mercadeo, el cual es definido por la Asociación Americana de Marketing como "la actividad, conjunto de instituciones y procesos para crear, comunicar, entregar e intercambiar ofertas que tienen valor para los clientes, socios y la sociedad en general" [1]. Una revisión cuidadosa de esta definición sugiere el análisis de los cambios importantes que ha sufrido el mercadeo en su evolución a lo largo de la historia: el mercadeo de hoy se basa en una relación más horizontal y participativa entre las compañías y sus clientes, siendo estos últimos participantes activos en la concepción y despliegue de los productos en el mercado. Por otro lado, el mercadeo actual más que estar dirigido a los clientes per se, realmente

se dirige al conjunto de instituciones, comunidades y grupos que participan a lo largo de toda la cadena [2].

En este contexto, el mercadeo forma parte de un conjunto de instrumentos que usan las compañías para llegar a sus clientes directamente y que está relacionado con cuatro áreas específicas: producto, precio, logística y promoción [3]. Particularmente, la publicidad se enmarca en el contexto de la promoción y se define en términos simples como un proceso de comunicación masivo diseñado para cambiar la actitud y el comportamiento de los receptores [4]. Al respecto, Kotler y Keller [3] elaboraron una definición más precisa que conceptúa la publicidad como "cualquier forma remunerada de presentación y promoción de ideas, bienes o servicios por parte de un auspiciante identificado".

De acuerdo con las definiciones anteriores, uno de los aspectos clave en el concepto de publicidad es el grado de involucramiento de los consumidores con el producto o servicio. Su relevancia es crítica, dado que impacta directamente el comportamiento durante el proceso de decisión de compra.

Como concepto de investigación, el grado de involucramiento fue introducido con el propósito de explicar el comportamiento de compra del usuario, teniendo en cuenta que el procesamiento de la información depende en gran parte de la relevancia de la información para el consumidor. En este sentido, este concepto hace referencia a la utilidad que se percibe sobre un producto basada en los intereses, valores y necesidades internas [5]. Desde este punto de vista, existen productos de alto involucramiento que son de gran importancia para el consumidor y están estrechamente relacionados con riesgos financieros o sociales de alto impacto (por ejemplo, una casa o vehículo). Por otro lado, la mayoría de las compras generalmente son de bajo involucramiento y son percibidas como poco importantes (por ejemplo, alimentos), lo cual no conlleva a una búsqueda exhaustiva

de información. Así, es generalmente válido en los esquemas de publicidad, que los productos de bajo involucramiento requieren poca información, pero ésta debe repetirse frecuentemente. Por su parte, los productos de alto involucramiento requieren el despliegue de más información, pero con una tasa de repetición menos frecuente [2].

En consecuencia, aunque la televisión, la radio o los periódicos han sido los medios tradicionales para el despliegue de publicidad por décadas, los sistemas de publicidad actuales han sido influenciados profundamente por el modelo de internet que ha dado paso a los esquemas online de publicidad [6]. De acuerdo con lo anterior, es posible distinguir cuatro componentes fundamentales: los anunciantes, los informantes, los clientes y los brokers (ver Figura 1).

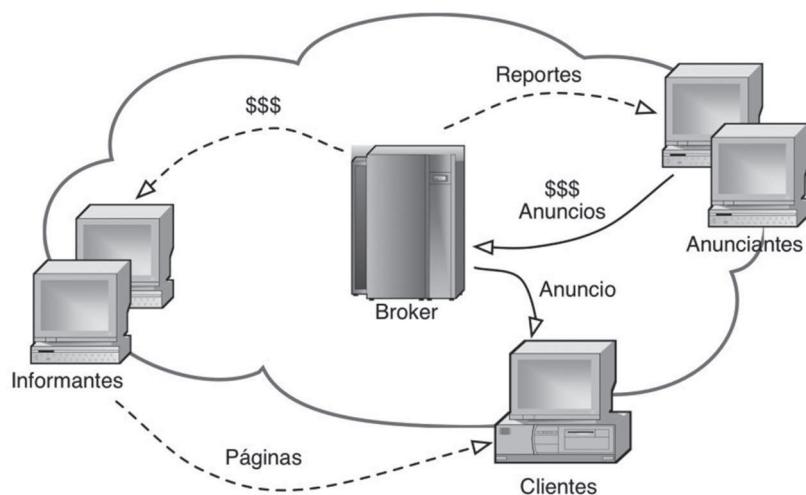


Figura 1. Modelo general de la publicidad en Internet.

Fuente: Haddadi et al. [6]

Los anunciantes son aquellos que manifiestan su intención de vender sus productos y servicios a través de anuncios publicitarios; los informantes (por ejemplo, sitios de noticias, blogs, etc.) proveen espacios para ver los anuncios, por ejemplo a través de banners publicitarios; los clientes son los dispositivos que habilitan el despliegue de las páginas de los informantes y los anuncios respectivos; finalmente, los brokers (por ejemplo Google o Yahoo) proporcionan las plataformas para reunir a los anunciantes, los informantes y los clientes. En este sentido, los brokers proporcionan anuncios para los clientes, reúnen estadísticas sobre el comportamiento de los anuncios en las páginas, recaudan el dinero de los anunciantes y efectúan los pagos a los informantes.

Pasando a otro contexto, otra corriente interesante que marca la evolución de la publicidad actual tiene que ver con los medios masivos, los cuales están dirigidos a una audiencia de consumidores más amplia que no se encuentra en su sitio de residencia o trabajo, sino en sitios públicos o simplemente en tránsito mientras se dirige a un lugar en particular. Con frecuencia, las pantallas publicitarias o *public displays* pueden encontrarse en sitios cotidianos como aeropuertos, estaciones de tren o restaurantes [7]. Esta corriente, conocida como señalización digital (*digital signage*), ha merecido un foco de atención particular en los últimos años dado su gran potencial desde el punto de vista de mercadeo, si se tiene en cuenta que generalmente este tipo de pantallas se ubican cerca de los sitios de

decisión de compra [8]. Recientemente, el modelo de *Smart TV*, entendido en términos simples como televisores o decodificadores con capacidades de cómputo conectados a la red [9], emerge como un nuevo ecosistema de pantallas conectadas y enriquecidas a través de aplicaciones que supone una nueva dimensión para la televisión interactiva y, por supuesto, con gran potencial para la señalización digital.

No obstante, pese a las nuevas oportunidades que encuentra la publicidad moderna en los esquemas de interactividad que marcan la evolución de internet y medios tradicionales como la televisión, aún el talón de Aquiles sigue siendo la ausencia de contenidos suficientemente personalizados y ajustados a las preferencias de los usuarios. Por naturaleza, los medios tradicionales de publicidad son en esencia de emisión o transmisión (*broadcast*). En este contexto, la publicidad ubicua nace como un nuevo paradigma que redimensiona el modelo de la publicidad tradicional.

El presente artículo plantea un modelo conceptual que puede servir como referente para orientar las investigaciones relacionadas con el despliegue de publicidad ubicua soportado en un esquema de cooperación *Smart TV – Smartphone*. Con este propósito, la sección uno realiza una conceptualización general sobre la publicidad ubicua; la sección dos presenta algunas generalidades sobre el proceso que se abordó para la construcción del estado actual de conocimiento sobre la temática, incluyendo aspectos metodológicos; la sección tres presenta el modelo conceptual

planteado, el cual incluye la identificación de las áreas de investigación más relevantes; y finalmente, en la sección cuatro se presentan algunas conclusiones.

1. LA PUBLICIDAD UBICUA

1.1. UN NUEVO PARADIGMA EN LA PUBLICIDAD

En términos simples, la publicidad ubicua se define como el uso de tecnologías de computación ubicua con fines publicitarios [10]. El concepto de computación ubicua se remonta a principios de los noventa cuando Marc Weiser concluye que "las tecnologías más profundas son aquellas que desaparecen. Ellas se entrelazan con nuestro diario vivir hasta hacerse indistinguibles" [11]: esa es la esencia de este nuevo paradigma que marca la evolución de la computación móvil. Por su parte, Boll et al. [12] agregan la siguiente conceptualización: "la computación ubicua describe la tendencia según la cual los dispositivos computacionales interconectados se entrelazan con los artefactos de nuestra vida diaria. Por consiguiente, el procesamiento, los sensores, la activación y la comunicación se encuentran embebidos en los dispositivos y ambientes, haciendo de la computación una parte integral de nuestra vida".

De acuerdo con lo anterior, la publicidad ubicua promueve una interacción con los usuarios en un nivel más íntimo y personalizado, que permite entregar información relevante en el momento y

contexto adecuado [13]. En este sentido, los dispositivos móviles modernos (*Smartphones*) son claros candidatos para llenar los vacíos que aún enfrenta la publicidad tradicional y varios trabajos de investigación han abordado sus propuestas de publicidad ubicua con un claro soporte de las características que son inherentes a este tipo de dispositivos (disponibilidad de información de perfiles, interacción en redes sociales, sensores, localización, entre otras). No obstante, un esquema de cooperación *Smart TV – Smartphone* puede potenciar las fortalezas de ambos mundos y hacer frente a los desafíos de la publicidad moderna. El naciente modelo de *Smart TV* no sólo es fuerte porque a diferencia de sus antecesores integra esquemas de computación y contenido distribuido (en la nube) de una forma optimizada para la televisión o la señalización digital, sino porque promueve un esquema de interacción simple con dispositivos como los *Smartphones* o tabletas. Este, sin lugar a dudas, es un valor agregado muy importante para el nuevo entorno generacional: "una generación conectada". Desde esta perspectiva, son muchas las oportunidades, pero también los retos que debe enfrentar la implementación de modelos de publicidad ubicua.

1.1.1. Publicidad ubicua: oportunidades y retos

En términos concretos, las oportunidades que ofrecen los modelos de publicidad ubicua se pueden resumir en los siguientes aspectos: i) transformación de los esquemas de *broadcast* tradicionales por esquemas interactivos; ii) personalización y

adaptación al contexto; iii) mayor precisión en las medidas de audiencia y respuesta de los grupos objetivo; y iv) mecanismos de persuasión automatizada a través de la interacción social entre los usuarios [14]. No obstante, la publicidad ubicua también enfrenta una serie de retos que deben ser considerados: i) manejo adecuado del contexto de personalización: correcto emparejamiento entre necesidades (usuarios) y productos (ofertantes); ii) conveniente elección de los medios: para la entrega del contenido (SMS, video, mensaje instantáneo, banner, etc.) y el despliegue de la información (TV, *Smartphone* o ambos); iii) manejo apropiado del canal interactivo: capacidad del usuario para responder a los avisos publicitarios de diferentes maneras (solicitar más información, contactar un agente de ventas, comprar); y iv) privacidad: manejo confiable de la información de los usuarios y los mecanismos para la entrega de ofertas [13].

De acuerdo al planteamiento anterior, es claro que los modelos de publicidad ubicua pueden ser aún más efectivos que los modelos online, gracias a su potencial de personalización e interacción desde dispositivos portables como los *Smartphones*. Si a esto se suma el potencial de un esquema de colaboración con el modelo naciente de *Smart TV*, el impacto generado sobre el público objetivo puede ser aún mayor si se tienen en cuenta siete aspectos clave: i) combina las bondades de un medio masivo por excelencia como lo es la televisión; ii) agrega interactividad; iii) mejora la experiencia de usuario al facilitar

la interacción a través de *Smartphones*, extendiendo las capacidades más allá del control remoto tradicional; iv) ofrece un modelo de conectividad y acceso a contenidos distribuidos (en la nube) como lo hacen los modelos online; v) redefine el modelo de publicidad ubicua tradicional al orientar contenidos no sólo a individuos sino también a grupos de individuos que comparten un espacio televisivo; vi) extiende sus fronteras al ofrecer la posibilidad de adaptar el contenido desplegado en más de una pantalla (aplicaciones n-screen) [15], de acuerdo con las capacidades de los dispositivos y el contexto específico; e igualmente, vii) los servicios que por naturaleza hacen parte de la telefonía móvil potencializan la experiencia del usuario (por ejemplo, al iniciar una llamada al servicio de ventas de forma inmediata).

2. ESTADO ACTUAL DEL CONOCIMIENTO

A continuación, se presenta el proceso de construcción de un modelo conceptual que sirve de base para trabajos de investigación relacionados con el despliegue de publicidad en entornos de computación ubicua soportados en esquemas de interacción *Smart TV - Smartphone*. En este sentido, la revisión del estado actual del conocimiento se abordó a través de una perspectiva de vigilancia tecnológica, con el objeto de establecer un panorama global de la temática que plantea las bases para la definición de focos de investigación relevantes en el contexto de la publicidad ubicua.

2.1. METODOLOGÍA DE REVISIÓN

En términos simples, la vigilancia tecnológica puede definirse como "la búsqueda, detección, análisis y comunicación de informaciones orientadas a la toma de decisiones sobre amenazas y oportunidades externas en el ámbito de la ciencia y tecnología" [16]. Para el propósito de la construcción del marco conceptual, la metodología para el desarrollo de la vigilancia tecnológica contempló las siguientes fases (Figura 2):

- **Planeación:** identifica las necesidades de información y el enfoque de la vigilancia tecnológica sobre el tema de interés. Durante esta fase, fue definido el objetivo de la vigilancia y se identificaron las fuentes de información más relevantes y las palabras clave que orientaron el proceso de búsqueda de

información. En la Tabla 1, se presenta un resumen al respecto.

Haciendo referencia a las palabras clave, inicialmente se realizó una búsqueda preliminar utilizando un conjunto de cinco palabras clave: *ubiquitous advertising*, *pervasive advertising*, *contextual advertising*, *pervasive computing*, *ubiquitous computing* y *Smart TV*. A partir de un estudio preliminar de los resúmenes de los artículos arrojados por la búsqueda fue posible determinar que algunas palabras clave arrojaban resultados irrelevantes para el contexto de investigación. Luego de este primer filtro, se tomó la decisión de enfocar el análisis en los resultados de las búsquedas realizadas a partir de las palabras clave señaladas en la Tabla 1

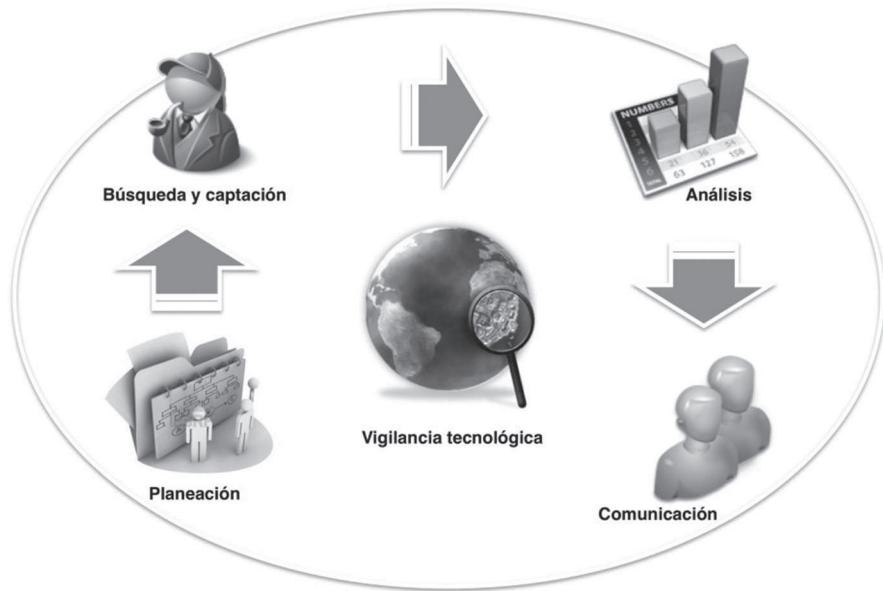


Figura 2. Metodología de la vigilancia tecnológica.

Tabla 1. Planeación de la vigilancia tecnológica

Objeto general del estudio	Construir una visión general del estado actual del conocimiento en el área de publicidad ubicua.
Objeto específico del estudio	Identificar los autores más relevantes Identificar las revistas y eventos más destacados en la temática Identificar los focos de investigación más relevantes
Identificación de fuentes de información	Google Scholar ACM Digital Library IEEE Xplore Digital Library Science Direct
Palabras clave	Pervasive advertising, ubiquitous advertising, contextual advertising

- **Búsqueda y captación:** durante esta fase se realiza el proceso de búsqueda usando las fuentes de información identificadas, de acuerdo con los objetivos planteados en la fase anterior. El principal resultado de esta fase es la construcción de un corpus compuesto por los artículos más relevantes sobre la temática del proyecto, que constituyen el insumo básico para el análisis que se realizará en la siguiente fase. En total se identificaron más de 200 artículos.
- **Análisis:** en esta fase se realiza un análisis exhaustivo de la información del corpus construido en la fase anterior de acuerdo con los objetivos planteados para el esquema de vigilancia tecnológica. Para este propósito, se tuvo el soporte de dos paquetes de software: Matheo Analyzer y Publish or Perish. Matheo analyzer es un software de apoyo a la

toma de decisiones que permite crear un cuadro de mando con mapas de información, síntesis e indicadores a partir de grandes conjuntos de información [17]. Por otro lado, Publish or Perish es un software libre que permite conocer el impacto de las publicaciones a través de la información que se obtiene de Google [18]. A manera de demostración sobre algunos resultados descriptivos, la Figura 3 resume autores relevantes identificados, la Figura 4 muestra algunos de los artículos más citados y, finalmente, la Figura 5 condensa algunas conferencias de interés.

- **Comunicación:** el objetivo de esta fase es socializar los resultados obtenidos durante el proceso de análisis realizado en la vigilancia tecnológica, resultados que han sido condensados en el presente artículo.

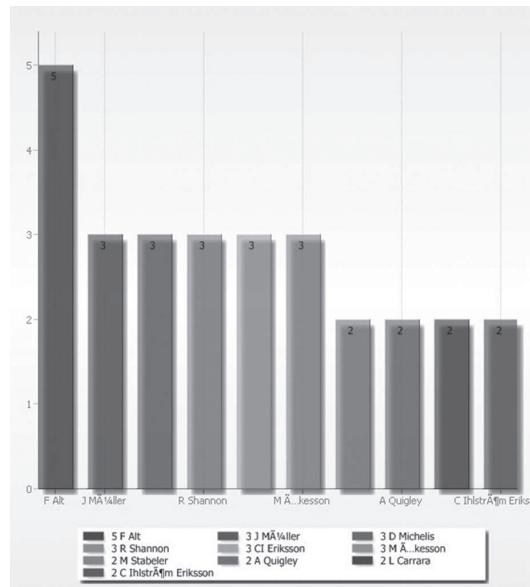


Figura 3. Autores más relevantes.

Fuente: Matheo Analyzer

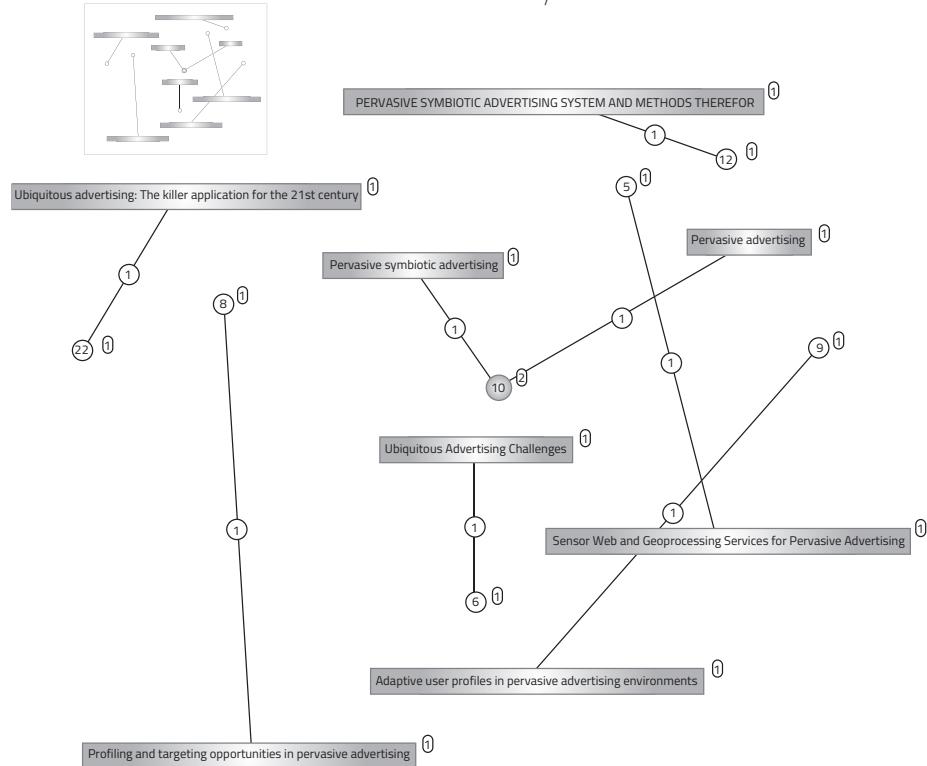


Figura 4. Artículos más citados.

Fuente: Matheo Analyzer.

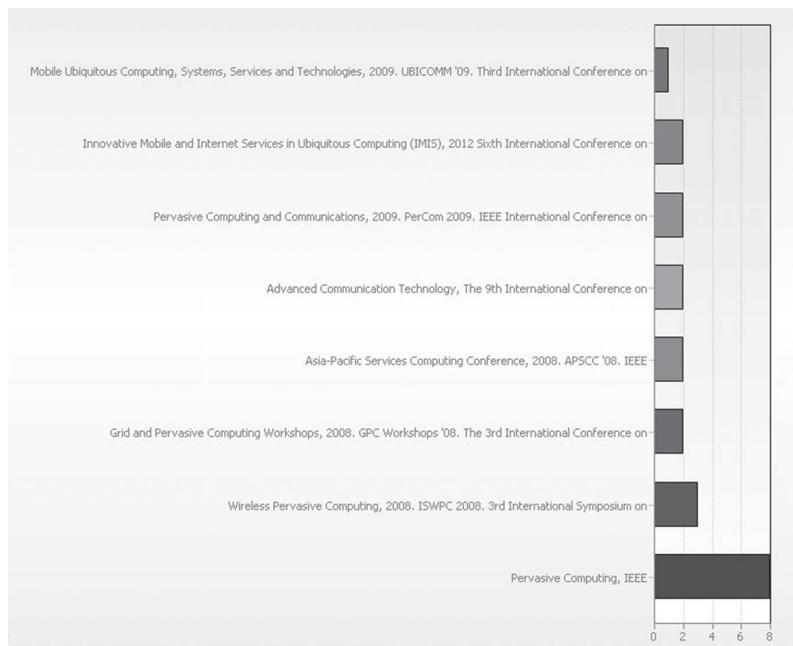


Figura 5. Revistas y conferencias más relevantes.

Fuente: Matheo Analyzer.

2.2. CONCLUSIONES PRELIMINARES DEL PROCESO DE VIGILANCIA TECNOLÓGICA

De acuerdo a los resultados encontrados durante el proceso, es posible plantear las siguientes conclusiones preliminares:

- Aunque la publicidad ubicua es un área de investigación que se ha venido cultivando desde hace varios años, el contexto de investigación planteado, que además considera un entorno de cooperación de los Smartphones con el naciente modelo de *Smart TV*, ha sido poco explorado. Como soporte a esta evidencia, la mayoría de trabajos relacionados han sido publicados en eventos más que en revistas especializadas.
- Un análisis más profundo de las publicaciones más relevantes y los trabajos de los autores más destacados demuestra que existe un énfasis importante en el área de señalización digital y el uso de *Smartphones* con fines de publicidad ubicua, pero no se considera un contexto propiamente dirigido a la incorporación del modelo de *Smart TV*.
- Igualmente, se puede inferir que existen dos contextos bien definidos para abordar un modelo de cooperación *Smart TV – Smartphone* con fines de publicidad ubicua:
 - Señalización digital, contexto en el cual el modelo de *Smart TV* puede

ampliar el potencial existente gracias a las capacidades de cómputo y mecanismos de interacción (sensores) que incorporan estos dispositivos sobre las viejas pantallas.

- Social TV, contexto que describe a un conjunto de personas viendo la televisión e interactuando entre sí y/o con amigos cercanos en un entorno social, usando sus *Smartphones*. En este sentido, las compañías publicitarias podrían tomar ventaja de esta interacción social para entregar ofertas más personalizadas usando en conjunto no sólo las capacidades de los Smartphones, sino también de los Smart TV.

3. PLANTEAMIENTO DEL MODELO CONCEPTUAL

Gracias a los resultados del proceso de vigilancia tecnológica y una revisión más exhaustiva de los trabajos más relevantes identificados durante el proceso fue posible plantear un modelo conceptual que evidencia las principales áreas de investigación en lo que respecta a la publicidad ubicua soportada en esquemas de cooperación Smart TV – Smartphone. Específicamente, el modelo describe los planteamientos más importantes en cada área y posibles brechas que pueden convertirse en un insumo importante para la formulación de futuras propuestas de investigación. La Figura 6 muestra un diagrama básico del modelo conceptual planteado.



Figura 6. Modelo conceptual.

Como se puede observar, el modelo conceptual plantea cuatro áreas de investigación a saber: Sistemas de recomendaciones para publicidad ubicua, aplicaciones n-screen y middleware de

cooperación Smart TV – Smartphone, gestión de privacidad y publicidad social. A continuación se realizará una revisión más detallada de cada una de las áreas de conocimiento identificadas.

3.1. SISTEMAS DE RECOMENDACIONES PARA PUBLICIDAD UBICUA

En términos simples, los sistemas de recomendaciones (SR) son herramientas *software* y técnicas que proporcionan sugerencias sobre ítems de interés para un usuario [19-21]. En términos más rigurosos, los SR basan la esencia de su funcionamiento en el siguiente planteamiento: si se considera que C es el conjunto de usuarios del sistema e I representa el conjunto de ítems que pueden ser recomendados, el número de elementos de los dos conjuntos puede ser muy grande, luego es necesario reducir el número de recomendaciones para disminuir la carga cognitiva del usuario a través de una función de utilidad $u: C \times I \rightarrow R$. Esta función mide el grado de satisfacción del usuario hacia un ítem, así que el sistema debe escoger ítems que maximicen la utilidad. El problema central de los SR radica en que u no está definida completamente en $C \times I$, sino en algunos subconjuntos del espacio. En otras palabras, el usuario no ha expresado su preferencia o rating para cada ítem, lo cual sugiere que una de las principales funciones de un SR es la de predecir los ratings para ítems no evaluados, de tal manera que se pueda maximizar la utilidad u [22].

En este sentido, diversas aproximaciones se han diseñado para mejorar la funcionalidad de los SR, entre las cuales se encuentran: i) filtrado colaborativo, que procesa correlaciones entre usuarios para reconocer su afinidad y asociar sus evaluaciones sobre los ítems; ii) filtrado basado en contenido, que usa las preferencias del usuario actual y predice los ratings con base en el grado de

similitud con ítems que se han evaluado en el pasado; y iii) filtrado basado en comunidad, que realiza recomendaciones de acuerdo con las preferencias de los amigos del usuario.

En el contexto de la publicidad ubicua, los sistemas de recomendaciones juegan un papel muy importante por cuanto son la base para empezar a construir recomendaciones personalizadas y disminuir el esfuerzo cognitivo requerido por el usuario para asimilar la información y mejorar su grado de involucramiento con la oferta. Diversas investigaciones han abordado los problemas comunes a los sistemas de recomendaciones tradicionales desde diferentes perspectivas: los sistemas basados en contenido y filtrado colaborativo, sufren la existencia del problema del usuario o ítem nuevo (cold start) cuando no se tiene la cantidad de ratings suficientes para realizar la recomendación; al respecto, [23-24] proponen algunas técnicas que pueden ser complementadas con la utilización de filtros basados en comunidad, según lo sugieren las investigaciones de Golbeck [25] y Massa et al [26]. Otros problemas, relacionados con la dispersión de los datos (pocos ratings para gran parte de los ítems disponibles), han sido abordados en [27-30]; por otro lado, la combinación de los diferentes tipos de filtrado para robustecer las capacidades del SR, conocido como filtrado híbrido, ha sido ampliamente estudiada a través del empleo de diferentes técnicas Burke [21], Pazzani [27], [31-36].

No obstante, los SR para publicidad ubicua agregan nuevos retos a los focos de investigación que tradicionalmente

se han abordado. En primer lugar, como fue señalado anteriormente, los SR convencionales operan en un espacio bidimensional *Usuario x Ítem*. Sin embargo, la publicidad ubicua requiere la incorporación de información del contexto que debe ser tenida en cuenta al momento de formular la recomendación, lo cual sugiere la ampliación del espacio tradicional *Usuario x Ítem* a un espacio *Usuario x Ítem x Contexto*. Al respecto, Kuflik et al [37], realiza algunos aportes importantes para el modelamiento del contexto del usuario en entornos más generales, mientras que Heckmann et al [38] va un paso más allá y define una metodología para la caracterización del contexto en entornos de publicidad ubicua; en el mismo sentido, Hussein et al [39] examina algunas técnicas para la incorporación de información contextual en los SR y Carolis [40] plantea la incorporación de algunos datos relacionados con el contexto de localización en un entorno de publicidad. Adicionalmente, aunque la información contextual aporta elementos relevantes, el enriquecimiento de los perfiles es clave para propósitos de publicidad, más allá de la disponibilidad de ratings Partridge et al [41].

Por otro lado, generalmente los SR dirigen sus recomendaciones a individuos; no obstante, en el campo de la señalización digital por ejemplo, se requiere que las recomendaciones estén dirigidas a un grupo de personas que se encuentran observando la pantalla. Al respecto, Masthoff [42] realiza una revisión de algunas técnicas para la caracterización de un perfil grupal; igualmente, algunos sistemas han sido

diseñados para entornos grupales: [43-52]. Específicamente, en el campo de publicidad, Carolis [40] plantea una aproximación para la caracterización y el modelamiento de los grupos, con el fin de entregar recomendaciones al conjunto de individuos. Sin embargo, el esquema de interacción tiene un componente fuertemente explícito, algo susceptible de mejorar en entornos computación ubicua. En ese orden de ideas, la inclusión de información contextual luce como un campo de investigación atractivo para los RS en este caso. Aunque el concepto de contexto es bastante amplio y puede incluir información que va desde la localización del usuario hasta datos de su círculo social cercano, su utilidad es evidente con miras a perfeccionar la personalización. Así por ejemplo, para alguien que disfruta de las bebidas gaseosas y los álbumes de rock, será mucho más interesante la publicidad sobre una refrescante bebida durante el tiempo que hace ejercicio.

Finalmente, es importante destacar algunos frameworks basados en técnicas de aprendizaje automático y minería de datos, que pueden ser útiles al momento de construir un SR para diferentes dominios como Apache Mahout [53], Lenskit Ekstrand et al [54] y Weka [55].

3.2. APPLICACIONES N-SCREEN Y MIDDLEWARE DE COOPERACIÓN SMART TV – SMARTPHONE

Como se dijo anteriormente, el naciente modelo de Smart TV expone un potencial interesante para extender las capacidades de interacción de las pantallas publicitarias convencionales tanto en el campo de

la señalización digital como en el de los avisos publicitarios del televíidente clásico, gracias a su capacidad de conexión con Smartphones o tabletas. Plataformas como MOVL [56] y Zeebox [57] han dado los primeros pasos para facilitar la interacción entre Smartphones y Smart TV; la primera define un modelo de conexión en la nube para este tipo de dispositivos y la segunda promete revolucionar el contexto de la televisión a través de la interacción con las redes sociales Twitter y Facebook usando clientes móviles, abriendo las puertas hacia un nuevo paradigma conocido como aplicaciones de múltiples pantallas (*n-screen*). En términos simples, el paradigma de múltiples pantallas busca tomar ventaja de las capacidades de cada pantalla para desplegar el contenido de la mejor manera en cada una de ellas, más en un esquema de cooperación, que en una simple réplica de información. En el contexto de la publicidad ubicua, los beneficios pueden ser claramente perceptibles si se tiene en cuenta escenarios de pantallas públicas (public displays) en los cuales la información desplegada en el Smart TV está dirigida al contexto grupal, mientras que la pantalla de los Smartphones es usada con fines de personalización Yoon et al [58]. Así por ejemplo, los usuarios podrían estar recibiendo avisos publicitarios personalizados en su teléfono, relacionados con algún tipo de contenido que observan en la pantalla.

Al respecto, tradicionalmente varios trabajos de investigación se han enfocado en mecanismos de interacción entre las pantallas y los Smartphones a través

de tecnologías de corto alcance como NFC o Bluetooth [59-61]. No obstante, en el marco de la publicidad ubicua es importante la existencia de un middleware que habilite no sólo la cooperación entre el Smart TV y los Smartphones, sino también el acceso a información contextual que pueda derivarse a partir de los mismos. En primera instancia, los trabajos de [8-7] realizan una caracterización más profunda de los entornos de señalización digital, proporcionan algunas guías de diseño de este tipo de espacios y plantean algunas consideraciones importantes que fijan un punto de partida relevante al momento de definir los requerimientos de un middleware de cooperación Smart TV – Smartphone con fines publicitarios. En el mismo sentido, Strohbach et al [62] realiza algunos planteamientos relevantes para la gestión del contexto en entornos de publicidad ubicua y realiza una revisión de sobre algunas plataformas que pueden habilitar el acceso a la información de los sensores y del contexto en general a través de los dispositivos móviles; [6]-[63] complementa el trabajo anterior planteando una arquitectura de referencia que involucra clientes móviles con propósitos publicitarios. De manera similar, otros trabajos [64-67] han explorado la interacción de Smartphones con pantallas en el marco del paradigma de múltiples pantallas, pero aún la exploración es incipiente para el caso de Smart TV y particularmente para entornos de publicidad ubicua.

De otro lado, uno de los parámetros más importantes de la publicidad es la evaluación de los resultados teniendo en cuenta el

precepto: "lo que es susceptible de medir, es susceptible de mejorar" Zaichkowsky [5]. Tradicionalmente, las medidas de audiencia en medios como la televisión responden a la medición de aspectos fundamentalmente demográficos que son reunidos a través de encuestas telefónicas o dispositivos especializados para entregar datos sobre los canales que están observando los televidentes. Igualmente, las pantallas públicas que se pueden encontrar en los grandes centros comerciales, pueden usar mecanismos alternos como cámaras especializadas en el registro de las visitas de los transeúntes [68-70]. Un modelo de cooperación Smart TV – Smartphone, no sólo ofrece la posibilidad de replicar algunas de las estrategias de medición de los modelos online (conteo de clics o seguimiento a los contenidos de interés del usuario), sino que también amplía sus potencialidades para los mismos usuarios a través de mecanismos de interacción que les permita realizar comentarios sobre los productos en un contexto social o hacer el seguimiento a sus propias preferencias gracias a la información disponible a través del TV o el Smartphone; esta interacción podría ser seguida por las compañías con fines de medición [13], [6].

3.3. GESTIÓN DE PRIVACIDAD CON FINES PUBLICITARIOS

Sin lugar a dudas, la privacidad de los usuarios al momento de acceder a la información de sus perfiles o incluso del contexto en el cual se encuentran con el ánimo de fortalecer el impacto de los anuncios publicitarios, no sólo

es un aspecto crítico en los entornos de publicidad ubicua, sino que ha sido su verdadero talón de Aquiles. Algunos estudios, han encontrado que un buen porcentaje de usuarios rechaza la idea de ser rastreados con fines publicitarios Turow [71], aún cuando esto signifique obtener ofertas más personalizadas [72-74]. Recientemente, redes sociales como Facebook son cuestionadas por el uso que pueda darse a la información que se encuentra en su poder y reiteradamente se persuade a sus gestores para que revisen las políticas al respecto, lo cual refleja la preocupación y la importancia que dan los usuarios a la privacidad de su información Coursey [75]. Aproximaciones similares son usadas por gigantes de la industria como Apple, Google o Microsoft en cuanto a la gestión de anuncios y aunque existen algunas soluciones para el manejo de cookies y alternativas de rastreo en general, éstas usualmente requieren un análisis detallado de la relación costo/beneficio Freudiger [76].

Como antecedentes, en el 2009 la Comisión Federal de Comercio - FTC (US. Federal Trade Commission) emitió algunas guías auto regulatorias para el comportamiento de la publicidad online FTC [72], como un esfuerzo para proteger la privacidad del consumidor en ausencia de una legislación más estricta Boucher [77]. En el mismo sentido, la Asociación Internacional para el Comercio al por Menor - POPAI (Point of Purchase Association International), liberó en el 2010 la primera versión de un conjunto de lineamientos de privacidad para el caso específico de señalización digital Smith [78];

aunque el código de POPAI es un punto de partida interesante para la auto-regulación de la industria al respecto, realmente no articula un conjunto completo de prácticas de información justa ni establece un marco de trabajo estricto de privacidad para las compañías dedicadas a la señalización digital. El lanzamiento de este tipo de iniciativas implica un mensaje claro para que las compañías y agencias de publicidad incorporen la gestión de privacidad en sus modelos actuales de negocio y de gestión de información; en la práctica, puede ser menos costoso integrar los controles de privacidad sobre tecnologías emergentes como en el caso de la publicidad ubicua que hacerlo sobre sistemas existentes y consolidados Geiger [79].

Por otro lado, algunos trabajos han planteado soluciones aplicables a contextos de publicidad ubicua orientados principalmente a teléfonos móviles. Adnostic Toubiana et al [80] y Privad Guha et al [81], han diseñado sistemas dirigidos a los navegadores para descargar los anuncios relevantes de forma offline y desplegarlos en momentos apropiados; Komulainen et al [82] ha propuesto un sistema de privacidad basado en permisos, en el cual la información del perfil es proporcionada por el consumidor y actualizada en la base de datos central; igualmente, la arquitectura del sistema MobiAd propuesta en Haddadi et al [83], considera un marco de referencia básico para la gestión de privacidad en entornos de telefonía móvil, en el cual persisten los desafíos de seguridad y privacidad inherentes a este tipo de tecnología. No obstante, aún se nota la ausencia de

estudios que especifiquen claramente cuándo, cómo y dónde los consumidores están dispuestos a ser parte de la publicidad móvil. Al respecto, una reflexión interesante, es que se ha encontrado que aunque la privacidad es una preocupación generalizada para la mayoría de los usuarios, ésta podría ser potencialmente compensada monetariamente o a través del valor percibido por la oferta Haddadi et al [6]. En un momento dado, un almacén de ropa por ejemplo, puede ofrecer cupones de descuento en la próxima compra de los usuarios a cambio del acceso a mayor información sobre su perfil personal.

En otro contexto, Geiger [79] plantea algunas consideraciones para la gestión de privacidad en entornos de señalización digital basadas en prácticas de información justa (FIP), que buscan ofrecer una guía para las compañías en cuanto al tratamiento de la información de los usuarios. En este sentido, Carolis [40] propone una aproximación para dirigir recomendaciones a un grupo de usuarios usando una pantalla no interactiva, a partir de los modelos individuales de los miembros que componen el grupo; en el contexto de la señalización digital, el ofrecimiento de anuncios publicitarios a grupos de personas más que a individuos particulares, puede constituir una ventaja en términos de la protección a la privacidad. Desde este punto de vista, el modelo de Smart TV sugiere un esquema de interacción enriquecido que podría contribuir en gran medida en dicha protección, si se tiene en cuenta que la información personalizada nunca será pública gracias a la posibilidad de extender el contenido a las pantallas de

los Smartphones de los usuarios. En ese orden de ideas, el desarrollo de sistemas que desplieguen contenido publicitario de propósito más general en pantallas públicas, al tiempo que entregan anuncios más personalizados en el dispositivo móvil, es una interesante línea de investigación.

3.4. PUBLICIDAD SOCIAL

Sin lugar a dudas, las redes sociales juegan un rol importante en la vida cotidiana de las personas en la actualidad. Desde el punto de vista de la publicidad, el interés de los comerciantes en las redes sociales radica principalmente en la posibilidad de facilitar a los consumidores una discusión más abierta sobre sus productos, una forma moderna de la modalidad "de boca en boca" (Word-of-mouth - WOM), la cual ha sido reconocida como una de las fuentes más influyentes en la transmisión de información desde los inicios de la sociedad humana Duan et al [84]. En este sentido, un principio básico que guía las investigaciones en esta línea es que se ha demostrado que los consumidores prefieren reunir información sobre sus compras potenciales a través de amigos o comunidades virtuales [85-86]; se estima que 6 de cada 10 adultos en los Estados Unidos han realizado algún tipo de investigación online sobre los productos y servicios que compran y cerca de un 25% han publicado comentarios o revisiones sobre sus compras Jasen [87]. En el contexto de las redes sociales, los usuarios tienen acceso a la publicidad y la información de los vendedores básicamente de dos maneras: a través de los anuncios en los sitios o las páginas de fidelidad a la marca (fan pages),

lo cual facilita una comunicación más directa entre oferentes y compradores.

Desde el punto de vista de la publicidad ubicua, es posible afirmar que existen dos grandes corrientes de investigación que resulta interesante abordar: en primera instancia, el enriquecimiento de los anuncios publicitarios a partir de la interacción social y en segunda instancia, el apoyo de la interacción en las redes sociales a los sistemas de recomendaciones que usan filtros basados en comunidad. Con respecto a la primera aproximación, algunos trabajos plantean la inclusión de nuevos tipos de avisos publicitarios que incluyen comentarios generados por los usuarios Ranganathan et al [13]; así mismo, el potencial que ofrecen redes como Gowalla, Foursquare y Facebook Places para brindar información de localización ha llamado la atención de otros investigadores: por ejemplo, [88-89] plantean la entrega de cupones o estímulos a los miembros que se registran en la localización de un tienda específica y Grove [90] ofrece estímulos similares a los usuarios de Foursquare que realizan visitas con más frecuencia.

De otro lado, otro campo de investigación fértil en este contexto está relacionado con la posibilidad de llevar las redes sociales a los escenarios de señalización digital; la posibilidad de incluir comentarios (quotes) de Facebook sobre una marca en particular en una pantalla pública por ejemplo, constituye un escenario de motivación para este tipo de trabajos. Al respecto, Spiegler et al [91] plantea un caso de estudio para el despliegue de comentarios de redes

sociales en pantallas públicas de pequeñas tiendas en Suiza; una interesante conclusión de este trabajo es que la capacidad de los clientes para procesar estímulos textuales en un ambiente de compra es limitada, luego el uso de la información de redes sociales debe examinarse con cuidado en este tipo de entornos. En este sentido, las investigaciones sugieren que debido a la naturaleza de las interacciones en las redes sociales, la puntualidad del contenido es un aspecto crucial; la información requiere ser digerida, interpretada y consumida en el menor tiempo posible, puesto que retardos excesivos pueden invalidar el contexto [92].

Por otro lado, el uso de redes sociales para mejorar la efectividad de las recomendaciones es otro campo de investigación atractivo pero aún incipiente. Como se dijo anteriormente, la evidencia sugiere que las personas confían más en las recomendaciones de sus amigos que en las recomendaciones similares de individuos anónimos, lo cual constituye el principio básico de esta aproximación [93]. En este tipo de sistemas, la recomendación está basada en los ratings proporcionados por los amigos del usuario, aunque recientemente se ha considerado también las relaciones e interacciones sociales de los usuarios en la adquisición de datos [94]. Dada la naciente exploración que se tiene en este campo, los resultados de las investigaciones son aún diversos. [25-26] reportan que las recomendaciones basadas en redes sociales no son más precisas que las derivadas a partir de los filtros colaborativos clásicos, excepto en

casos especiales donde los ratings de los usuarios para un ítem específico son altamente controversiales, o cuando se usan como alternativa para solucionar los inconvenientes asociados a los "usuarios" o "ítems" nuevos (cold start). Otros trabajos han demostrado que en algunos casos, la adición de datos sociales a los sistemas tradicionales mejora los resultados de las recomendaciones con respecto a los datos de similitud de perfiles [95-96].

Recientemente, un ingrediente adicional se ha sumado a las investigaciones en este contexto: las redes de confianza; en términos simples, este concepto se refiere a una red social que expresa qué tanto confían los miembros de una comunidad entre sí. Algunos ejemplos de esta aproximación pueden evidenciarse en la red social Goldbeck's Film Trust o EOpinions.com Golbeck [25], las cuales mantienen una red de confianza al indagar en los usuarios acerca de las personas en las cuales confían. Los sistemas de recomendaciones basados en esta técnica, usan el conocimiento que se origina a partir de las relaciones de confianza, para brindar recomendaciones más personalizadas a través de operadores de propagación y agregación, que permiten a los usuarios recibir recomendaciones de ítems que han logrado una alta calificación por parte de los usuarios en su red o aún por las personas que hacen parte de las redes de confianza de estos individuos. Algunos trabajos relacionados pueden ser consultados en [97-99]. No obstante, aunque existen algunos trabajos en el contexto de la publicidad ubicua [100-

[102], la investigación aún es incipiente, lo cual no descarta su enorme potencial, más si se tiene en cuenta el enriquecimiento de los mecanismos de interacción que se puede lograr a través de un modelo de cooperación Smart TV – Smartphone. Así las cosas, las recomendaciones publicitarias que se despliegan en una pantalla por ejemplo, podrían derivarse no sólo a partir de la similitud entre los usuarios que la observan, sino también del nivel de confianza que pueda inferirse de sus vínculos sociales, al tiempo que reciben recomendaciones de sus amigos cercanos directamente en su teléfono móvil.

4. CONCLUSIONES

La publicidad ubicua marca un hito importante en la evolución de los mecanismos de promoción que tradicionalmente se han conocido en el área del mercadeo. La posibilidad de enriquecer los avisos publicitarios a través de la personalización, el involucramiento de la información del contexto y los mecanismos de interacción implícita a través de las capacidades de los Smartphones y Smart TV modernos, son algunos de los beneficios directos de este nuevo tipo de publicidad.

Los sistemas de recomendaciones para publicidad ubicua, constituyen uno de los campos núcleo de la investigación que actualmente se adelanta sobre esta área. Específicamente, la publicidad ubicua impone nuevos retos de investigación relacionados con la extensión del espacio bidimensional Usuario x Ítem tradicional, hacia un espacio Usuario x Ítem x Contexto

y la generación de recomendaciones hacia entornos grupales más que individuales, puntualmente en escenarios de señalización digital (Digital Signage).

El naciente modelo de Smart TV promete revolucionar el concepto de la televisión moderna y por consiguiente el de la publicidad, si se tiene en cuenta que éste ha sido su canal masivo por excelencia. No obstante, es de especial relevancia el potencial de Smart TV en escenarios de señalización digital, donde la investigación aún es incipiente. La mayoría de los trabajos relacionados se han enfocado en la capacidad de interacción con pantallas públicas a través de tecnologías como Bluetooth o NFC, lo cual sugiere un campo fértil de investigación en nuevos mecanismos y middleware de interacción que tome ventaja de las capacidades de Smart TV, no sólo para enriquecer la promoción como tal, sino también para incorporar nuevos modelos de medidas de audiencia.

La privacidad es sin lugar a dudas uno de los talones de Aquiles de la publicidad ubicua y por lo tanto un campo de investigación relevante, que de hecho abarca aspectos legales que rebasan los aspectos meramente técnicos y en el que comienzan a darse algunas iniciativas para fijar reglas claras al respecto. En términos generales, los antecedentes sugieren que los usuarios están dispuestos a permitir el acceso a la información de sus perfiles, siempre y cuando se perciba un beneficio claro que va más allá de la simple personalización de ofertas. De otro lado, en el contexto

de la señalización digital, la cooperación Smart TV – Smartphone ofrece una posibilidad interesante de protección a la privacidad, gracias al establecimiento de perfiles grupales públicos y perfiles individuales privados que son explotados a través de capacidades de múltiples pantallas (n-screen).

El campo de la publicidad social, se abre paso en el contexto moderno gracias a la enorme influencia de las redes sociales y un principio básico que establece que las personas prefieren reunir información sobre sus compras potenciales a través de amigos. En este sentido, el enriquecimiento de anuncios publicitarios con información derivada de la interacción social, incluso en escenarios de señalización digital, y el apoyo que pueda agregar la dinámica de las redes sociales a la generación de recomendaciones en sistemas que usan filtros basados en comunidad, son dos de las corrientes más fuertes de investigación que se vislumbran en este campo.

AGRADECIMIENTOS

Agradecimientos especiales a la Vicerrectoría de Investigaciones de la Universidad del Cauca y al Grupo de Ingeniería Telemática por el soporte brindado en el desarrollo del trabajo.

REFERENCIAS

- [1] AMA - American Marketing Association. (2013). Marketing Power - American Marketing Association. Recuperado en junio de 2013, de <http://www.marketingpower.com/Pages/default.aspx>
- [2] Müller, J., Alt, F. & Michelis, D. (2011). Pervasive Advertising. Londres, Inglaterra: Springer, pp. 1–29.
- [3] Kotler, P. & Keller, K. L. (2012). Marketing management. Upper Saddle River, N.J., EE.UU.: Prentice Hall.
- [4] Meffert, H. (2012). Marketing: Grundlagen marktorientierter Unternehmensführung. Berlín, Alemania: Gabler Verlag.
- [5] Zaichkowsky, J. L. (1985.) Measuring the Involvement Construct. *J. Consum. Res.*, 12(3), pp. 341–352.
- [6] Haddadi, H.; Hui, P.; Henderson, T. & Brown, I. (2011). Targeted Advertising on the Handset: Privacy and Security Challenges. En Müller, J., Alt, F., & Michelis, D., (Eds.). Pervasive Advertising (119–137). Londres, Inglaterra: Springer.
- [7] Stalder, U. (2011). Digital Out-of-Home Media: Means and Effects of Digital Media in Public Space. En Müller, J., Alt, F., & Michelis, D., (Eds.). Pervasive Advertising (31–56). Londres, Inglaterra: Springer.
- [8] Rui, J. & Cardoso, J.C.S. (2011). Opportunities and Challenges of Interactive Public Displays as an Advertising Medium. En Müller, J., Alt, F., & Michelis, D., (Eds.). Pervasive Advertising (139–157). Londres, Inglaterra: Springer.
- [9] Jewett, F. (2011). Why Smart TV is the next big thing. Recuperado en junio de 2013, de http://www.uievolution.com/mobileconnect/Mobile_Connect_June_2011.pdf

- [10] Müller, J., Alt, F. & Michelis, D. (2011). Pervasive Advertising. Londres, Inglaterra: Springer, pp. 1–29.
- [11] Weiser, M. (1999). The computer for the 21st century. *Sigmobile Mob Comput Commun Rev*, 3(3), pp. 3–11.
- [12] Boll, S., Schmidt, A., Kern, D., Streng, S., & Holleis, P. (2008). Magic Beyond the Screen. *Ieee Multimed.*, 15(4), pp. 8–13.
- [13] Ranganathan, A. & Campbell, R. H. (2002). Advertising in a pervasive computing environment. En Proceedings of the 2nd international workshop on Mobile commerce. New York, NY, EE.UU., pp. 10–14.
- [14] Fogg, B. J. (diciembre, 2002). Persuasive technology: using computers to change what we think and do. *Ubiquity*, 2002(12), pp. 89–120.
- [15] Otero, N. & Rui, J. (2009). Worth and Human Values at the Centre of Designing Situated Digital Public Displays. *Int J Adv Pervasive Ubiquitous Comput*, 1(4), pp. 1–13.
- [16] Ashton, W. B. (1997). Keeping abreast of science and technology: technical intelligence for business. Columbus, OH, EE.UU.: Battelle Press.
- [17] Matheo-Software. (2013). Matheo Analyzer. Recuperado en enero de 2013, de <http://www.matheo-software.com/es/productos/matheo-analyzer.html>
- [18] Harzing A-W. (2013). Publish or Perish. Recuperado en enero de 2013, de <http://www.harzing.com/pop.htm>
- [19] Mahmood, T. & Ricci, F. (2009). Improving recommender systems with adaptive conversational strategies. En Proceedings of the 20th ACM conference on Hypertext and hypermedia. Nueva York, NY, EE.UU., pp. 73–82.
- [20] Resnick, P. & Varian, H. R. (1997). Recommender systems. *Commun Acm*, 40(3), pp. 56–58.
- [21] Burke, R. (2007). Hybrid Web Recommender Systems. En Brusilovsky, P., Kobsa, A. & Nejdl, W. (Eds.). The Adaptive Web (377–408). Berlín, Alemania: Springer
- [22] Ricci, F. (2011). Recommender systems handbook. Nueva York, NY, EE.UU.: Springer.
- [23] Rashid, A. M., Albert, I., Cosley, D., Lam, S. K., McNee, S. M., Konstan, J. A. & Riedl, J. (2002). Getting to know you: learning new user preferences in recommender systems. En Proceedings of the 7th international conference on Intelligent user interfaces. Nueva York, NY, EE.UU., pp. 127–134.
- [24] Yu, K., Schwaighofer, A., Tresp, V., Xu, X. & Kriegel, H.P. (2004). Probabilistic memory-based collaborative filtering. *Ieee Trans. Knowl. Data Eng.*, 16(1), pp. 56–69.
- [25] Golbeck, J. (2006). Generating predictive movie recommendations from trust in social networks. En Proceedings of the 4th international conference on Trust Management. Berlín, Alemania, pp. 93–104.

- [26] Massa, P. & Avesani, P. (2004). Trust-Aware Collaborative Filtering for Recommender Systems. En Meersman, R. & Tari, Z. (Eds.). *On the Move to Meaningful Internet Systems 2004: CoopIS, DOA, and ODBASE* (492–508). Berlín, Alemania: Springer.
- [27] Pazzani, M. J. (diciembre, 1999). A Framework for Collaborative, Content-Based and Demographic Filtering. *Artif. Intell. Rev.*, 13(5–6), pp. 393–408.
- [28] Huang, Z., Chen, H. & Zeng, D. (enero, 2004). Applying associative retrieval techniques to alleviate the sparsity problem in collaborative filtering. *Acm Trans Inf Syst*, 22(1), pp. 116–142.
- [29] Symeonidis, P. (2008). Content-based Dimensionality Reduction for Recommender Systems. En Preisach, C., Burkhardt, P.D.H., Schmidt-Thieme, P.D.L. & Decker, P.D.R. (Eds.). *Data Analysis, Machine Learning and Applications* (619–626). Berlín, Alemania: Springer.
- [30] Billsus, D. & Pazzani, M. J. (1998). Learning Collaborative Information Filters. En *Proceedings of the Fifteenth International Conference on Machine Learning*. San Francisco, CA, EE.UU., pp. 46–54.
- [31] Balabanović, M. & Shoham, Y. (1997). Fab: content-based, collaborative recommendation. *Commun Acm*, 40(3), pp. 66–72.
- [32] Basu, C., Hirsh, H., & Cohen W. (1998). "Recommendation as classification: using social and content-based information in recommendation. En *Proceedings of the fifteenth national/tenth conference on Artificial intelligence/Innovative applications of artificial intelligence*. Menlo Park, CA, EE.UU., pp. 714–720.
- [33] Li, Q. & Kim, B.M. (2003). An approach for combining content-based and collaborative filters. En *Proceedings of the sixth international workshop on Information retrieval with Asian languages - Volume 11*, Stroudsburg, PA, EE.UU., pp. 17–24.
- [34] Schein, A. I., Popescul, A., Ungar, L. H. & Pennock, D. M. (2002). Methods and metrics for cold-start recommendations. En *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*. Nueva York, NY, EE.UU., pp. 253–260.
- [35] Spaeth, A. & Desmarais, M. C. (2013). Combining Collaborative Filtering and Text Similarity for Expert Profile Recommendations in Social Websites. En Carberry, S., Weibelzahl, S., Micarelli, A. & Semeraro, G. (Eds.). *User Modeling, Adaptation, and Personalization* (178–189). Berlín, Alemania: Springer.
- [36] Rongfei, J., Maozhong, J., & Chao, L. (2010). A new clustering method for collaborative filtering. En *2010 International Conference on Networking and Information Technology (ICNIT)*, pp. 488–492.
- [37] Kuflik, T., Berkovsky, S., Carmagnola, F., Heckmann, D. & Krüger, A. (2009). *Advances in Ubiquitous User Modelling: Revised Selected Papers*. Berlín, Alemania: Springer.

- [38] Heckmann, D. & Krueger, A. (2003). A User Modeling Markup Language (UserML) for Ubiquitous Computing. En Brusilovsky, P., Corbett, A. & de Rosis, F. (Eds.). *User Modeling 2003* (393–397). Berlín, Alemania: Springer.
- [39] Hussein, T., Linder, T., Gaulke, W., & Ziegler, J. (2010). A Framework and an Architecture for Context-Aware Group Recommendations. En Kolschoten, G., Herrmann, T. & Lukosch, S. (Eds.). *Collaboration and Technology* (121–128). Berlín, Alemania: Springer.
- [40] Carolis, B. D. (2011). Adapting News and Advertisements to Groups. En *Pervasive Advertising*, J. Müller, F. Alt, and D. Michelis, Eds. Springer London, pp. 227–246.
- [41] Partridge K. and Begole B., (2011) "Activity-Based Advertising," En Müller, J., Alt, F., & Michelis, D., (Eds.). *Pervasive Advertising* (83–101). Londres, Inglaterra: Springer.
- [42] Masthoff, J. (febrero, 2004). Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers. *User Model. User-Adapt. Interact.*, 14(1), pp. 37–85.
- [43] Jameson, A. (2004). More than the sum of its members: challenges for group recommender systems. En Proceedings of the working conference on Advanced visual interfaces, Nueva York, NY, EE.UU., pp. 48–54.
- [44] Santos, R., Marreiros, G., Ramos, C., Neves, J. & Bulas-Cruz, J. (2006). Multi-agent Approach for Ubiquitous Group Decision Support Involving Emotions. En Ma, J., Jin, H., Yang, L.T. & Tsai, J.J.P. (Eds.). *Ubiquitous Intelligence and Computing* (1174–1185). Berlín, Alemania: Springer..
- [45] O'Connor, M., Cosley, D., Konstan, J.A. & Riedl, J. (2002). PolyLens: A Recommender System for Groups of Users. En Prinz, W., Jarke, M., Rogers, Y., Schmidt, K. & Wulf, V. (Eds.). *ECSCW 2001* (199–218). Países Bajos: Springer.
- [46] McCarthy, J.F. & Anagnost, T.D. (1998). MusicFX: an arbiter of group preferences for computer supported collaborative workouts. *Proceedings of the 1998 ACM conference on Computer supported cooperative work*, Nueva York, NY, EE.UU., pp. 363–372.
- [47] Kabassi, K. (febrero, 2010). Personalizing recommendations for tourists. *Telematics Informatics*, 27(1), pp. 51–66.
- [48] Ardissono, L., Goy, A., Petrone, G., Segnan, M. & Torasso, P. (2003). Intrigue: Personalized recommendation of tourist attractions for desktop and hand held devices. *Appl. Artif. Intell.*, 17(8–9), pp. 687–714.
- [49] Kim, J.K., Kim, H.K., Oh, H.Y. & Ryu, Y.U. (2010). A group recommendation system for online communities. *Int. J. Inf. Manag.*, 30(3), pp. 212–219.
- [50] Christensen, I.A. & Schiaffino S. (2011). Entertainment recommender systems for group of users. *Expert Syst. Appl.*, 38(11), pp. 14127–14135.

- [51] Crossen, A., Budzik, J. & K. Hammond, J. (2002). Flytrap: intelligent group music recommendation. Proceedings of the 7th international conference on Intelligent user interfaces, Nueva York, NY, EE.UU., pp. 184–185.
- [52] Chao, D.L., Balthrop, J. & Forrest, S. (2005). Adaptive radio: achieving consensus using negative preferences. Proceedings of the 2005 international ACM SIGGROUP conference on Supporting group work, Nueva York, NY, EE.UU., pp. 120–123.
- [53] Mahout. (2013). Apache Mahout: Scalable machine learning and data mining. Recuperado el 5 de julio de 2013, de <http://mahout.apache.org/>.
- [54] Ekstrand, M.D., Ludwig, M., Kolb, J. & Riedl, J.T. (2011). LensKit: a modular recommender framework. Proceedings of the fifth ACM conference on Recommender systems, Nueva York, NY, EE.UU., pp. 349–350.
- [55] Weka. (2013). Weka 3 - Data Mining with Open Source Machine Learning Software in Java. Recuperado el 5 de julio de 2013, de <http://www.cs.waikato.ac.nz/ml/weka/>.
- [56] MOVL. (2013). MOVL. Recuperado el 5 de julio de 2013, de <http://movl.com/>.
- [57] Zeebox. (2013). Zeebox - Get the free app. Recuperado el 5 de julio de 2013, de <http://zeebox.com/>.
- [58] Yoon, C., Um, T. & Lee, H. (2012). Classification of N-Screen Services and its standardization. 2012 14th International Conference on Advanced Communication Technology (ICACT), pp. 597–602.
- [59] Holleis, P., Broll, G. & Böhm, S. (2010). Advertising with NFC. Workshop on Pervasive Advertising and Shopping, in conjunction with the 8th International Conference on Pervasive Computing (Pervasive 2010), Helsinki, Finlandia.
- [60] Rui, J., Otero, N., Izadi, S. & Harper, R. (2008). Instant Places: Using Bluetooth for Situated Interaction in Public Displays. *ieee Pervasive Comput.*, 7(4), pp. 52–57.
- [61] Mahato, H., Kern, D., Holleis, P. & Schmidt, A. (2008). Implicit personalization of public environments using bluetooth. *CHI '08 Extended Abstracts on Human Factors in Computing Systems*, Nueva York, NY, EE.UU., pp. 3093–3098.
- [62] Strohbach, M., Bauer, M., Martin, M. & Heben, B. (2011). Managing Advertising Context. En Müller, J., Alt, F., & Michelis, D., (Eds.). *Pervasive Advertising* (185–205). Londres, Inglaterra: Springer.
- [63] Nguyen, Q.N. & Hoang P.M. (2010). Push delivery of product promotion advertisements to mobile users. *Proceedings of the Pervasive Advertising and Shopping 2010 Workshop*, Helsinki, Finlandia.
- [64] Otero, N. & Rui, J. (2009). Worth and Human Values at the Centre of Designing Situated Digital Public Displays. *Int. J. Adv. Pervasive Ubiquitous Comput.*, 1(4), pp. 1–13, 34.
- [65] Santos, P., Ribeiro, F.R. & Metrolho, J. (2012). Using pervasive computing technologies to deliver personal and public ads in public spaces. 2012 7th Iberian Conference on Information Systems and Technologies (CISTI), pp. 1–6.

- [66] Michelis, D. & Send, H. (2009). Engaging Passers-by with Interactive Screens-A Marketing Perspective. GI Jahrestagung, pp. 3875–3881.
- [67] Kaasinen, A. & Yoon, Y.I. (2012). Mobile advertising model in N-Screen environment for CSCW. 2012 7th International Conference on Computing and Convergence Technology (ICCCT), pp. 140–143.
- [68] Rui, J. & Soares, A.M. (2010). Towards new advertising models for situated displays. Proceedings of the 3rd workshop on Pervasive Advertising, Helsinki, Finlandia.
- [69] May, M., Körner, C., Hecker, D., Pasquier, M., Hofmann, U. & Mende, F. (2009). Modelling Missing Values for Audience Measurement in Outdoor Advertising Using GPS Data. GI Jahrestagung, pp. 3993–4006.
- [70] Schrammel, J., Mattheiss, E., Döbelt, S., Paletta, L., Almer, A. & Tscheligi, M. (2011). Attentional Behavior of Users on the Move Towards Pervasive Advertising Media. En Müller, J., Alt, F., & Michelis, D., (Eds.). Pervasive Advertising (287–307). Londres, Inglaterra: Springer.
- [71] Turow, J., King, J., Hoofnagle, C.J., Bleakley, A. & Hennessy, M. (2013). Americans Reject Tailored Advertising and Three Activities that Enable It by:: SSRN. Recuperado el 7 de julio de 2013, de http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1478214.
- [72] FTC. Federal Trade Commission. (febrero, 2009). Staff Report: "Self-Regulatory Principles For Online Behavioral Advertising: Tracking, Targeting, and Technology" Recuperado el 7 de julio de 2013, de <http://www.ftc.gov/os/2009/02/P085400behavadreport.pdf>.
- [73] Wirespring. (2013). Digital signage networks must guarantee viewer privacy. Recuperado el 7 de julio de 2013, de http://www.wirespring.com/dynamic_digital_signage_and_interactive_kiosks_journal/articles/Digital_signage_networks_must_guarantee_viewer_privacy-569.html.
- [74] TruMedia. (2013). Facial Recognition Boards Will Never Record, Share Data - MediaBuyerPlanner. Recuperado el 7 de julio de 2013, de <http://www.mediabuyerplanner.com/entry/34111/trumedia-facial-recognition-boards-will-never-record-share-data/>.
- [75] Coursey, D. (2013). After Criticism, Facebook Tweaks Friends List Privacy Options, PCWorld. Recuperado el 7 de julio de 2013, de http://www.pcworld.com/article/184418/After_Criticism_Facebook_Changes_Friend_List_Privacy_Options.html.
- [76] Freudiger, J., Vratonjic, N. & Hubaux J.P. (2009) Towards privacy-friendly online advertising. IEEE Web 2.0 Security and Privacy (W2SP).
- [77] Boucher, R. (2013). Behavioral ads: The need for privacy protection. Recuperado el 7 de julio de 2013, de <http://thehill.com/special-reports/technology-september-2009/60253-behavioral-ads-the-need-for-privacy-protection>.

- [78] Smith, G. (2013). Taking Consumer Privacy Seriously, POPAI's Digital Signage Group Releases Code of Conduct. Recuperado el 7 de julio de 2013, de http://www.popai.com/2010/02/08/taking-consumer-privacy-seriously-popais-digital-signage-group-releases-code-of-conduct/?cat_id=1.
- [79] Geiger, H.L. (2011). A Standard for Digital Signage Privacy. En Müller, J., Alt, F., & Michelis, D., (Eds.). *Pervasive Advertising* (103–117). Londres, Inglaterra: Springer.
- [80] Toubiana, V., Narayanan, A., Boneh, D., Nissenbaum, H. & Barocas, S. (febrero, 2010). Adnostic: Privacy Preserving Targeted Advertising. NDSS.
- [81] Guha, S., Reznichenko, A., Tang, K., Haddadi, H. & Francis, P. (2009). Serving Ads from localhost for Performance, Privacy, and Profit. HotNets.
- [82] Komulainen, H., Ristola, A. & Still, J. (2006). Mobile advertising in the eyes of retailers and consumers - empirical evidence from a real-life experiment. International Conference on Mobile Business. ICMB '06, pp. 37–37.
- [83] Haddadi, H., Hui, P. & Brown, I. (2010). MobiAd: private and scalable mobile advertising. Proceedings of the fifth ACM international workshop on Mobility in the evolving internet architecture, Nueva York, NY, EE.UU., pp. 33–38.
- [84] Duan, W., Gu, B. & Whinston, A. B. (2008). The dynamics of online word-of-mouth and product sales—An empirical investigation of the movie industry. *J. Retail.*, 84(2), pp. 233–242.
- [85] Wang, M.C.H., Wang E.S.T., Cheng, J.M.S. & Chen, A.F.L. (2009). Information quality, online community and trust: a study of antecedents to shoppers' website loyalty. *Int. J. Electron. Mark. Retail.*, 2(3), pp. 203–219.
- [86] Jepsen, A.L. (2006). Information Search in Virtual Communities: Is it Replacing Use of Off Line Communication?. *J. Mark. Commun.*, 12(4), pp. 247–261.
- [87] Jasen, J. (2013). Online Product Research. Pew Research Center's Internet & American Life Project. Recuperado el 7 de julio de 2013, de <http://www.pewinternet.org/Reports/2010/Online-Product-Research.aspx>.
- [88] Ailawadi, K. L., Beauchamp, J. P., Dontu, N., Gauri, D. K., & Shankar, V. (2009). Communication and Promotion Decisions in Retailing: A Review and Directions for Future Research. *J. Retail.*, 85(1), pp. 42–55.
- [89] Bustos, L. (2013). 110 Ways Retailers are Using Social Media Marketing. Recuperado el 7 de julio de 2013, de <http://www.getelastic.com/social-media-examples/>.
- [90] Grove, J.V. (2013). Mayors of Starbucks Now Get Discounts Nationwide with Foursquare. Recuperado el 7 de julio de 2013, de <http://mashable.com/2010/05/17/starbucks-foursquare-mayor-specials/>.
- [91] Spiegler, E.D., Hildebrand, C. & Michahelles, F. (2011). Social Networks in Pervasive Advertising and Shopping. En Müller, J., Alt, F., & Michelis, D.,

- (Eds.). Pervasive Advertising (207–225). Londres, Inglaterra: Springer.
- [92] Ferdinando, A.Di., Rosi, A., Lent, R., Manzalini, A. & Zambonelli, F. (2009). MyAds: A system for adaptive pervasive advertisements. *Pervasive Mob. Comput.*, 5(5), pp. 385–401.
- [93] Sinha, R.R. & Swearingen, K. (2001). Comparing Recommendations Made by Online Systems and Friends. DELOS workshop: personalisation and recommender systems in digital libraries, vol. 106.
- [94] Ricci, F., Rokach, L. & Shapira, B. (2011). Introduction to Recommender Systems Handbook. En Ricci, F., Rokach, L., Shapira, B. & Kantor, P.B. (Eds.). Recommender Systems Handbook. Nueva York, NY, EE.UU: Springer. pp. 1–35.
- [95] Groh, G. & Ehmig, C. (2007). Recommendations in taste related domains: collaborative filtering vs. social filtering. Proceedings of the 2007 international ACM conference on Supporting group work, Nueva York, NY, EE.UU., pp. 127–136.
- [96] Guy, I., Zwerdling, N., Carmel, D., Ronen, I., Uziel, E., Yoge, S. & Ofek-Koifman, S. (2009). Personalized recommendation of social software items based on social relations. Proceedings of the third ACM conference on Recommender systems, Nueva York, NY, EE.UU., pp. 53–60.
- [97] Avesani, P., Massa, P. & Tiella, R. (2005). Moleskiingit: a trust-aware recommender system for ski mountaineering. *Int. J. Infonomics*, vol. 20.
- [98] O'Donovan, J. & Smyth, B. (2005). Trust in recommender systems. Proceedings of the 10th international conference on Intelligent user interfaces, Nueva York, NY, EE.UU., pp. 167–174.
- [99] Victor, P., Cornelis, C., De Cock, M. & Teredesai, A. M. (2008). Key figure impact in trust-enhanced recommender systems. *Ai Commun.*, 21(2–3), pp. 127–143.
- [100] Clemons, E. K., Barnett, S. & Appadurai, A. (2007). The future of advertising and the value of social network websites: some preliminary examinations, Proceedings of the ninth international conference on Electronic commerce, Nueva York, NY, EE.UU., pp. 267–276.
- [101] Yang, W.S. & Dia, J.B. (2008). Discovering cohesive subgroups from social networks for targeted advertising. *Expert Syst. Appl.*, 34(3), pp. 2029–2038.
- [102] Yang, W.S., Dia, J.B., Cheng, H.C. & Lin, H.T. (2006). Mining Social Networks for Targeted Advertising. Proceedings of the 39th Annual Hawaii International Conference on System Sciences, 2006. HICSS '06, 6, p. 137a.

FACTORES QUE IMPACTAN EN LA SELECCIÓN E IMPLANTACIÓN DEL SISTEMA DE GESTIÓN ISO/TS 16949: CASO DEL SECTOR INDUSTRIAL DE AUTOPARTES DE LA CIUDAD DE BOGOTÁ

FACTORS THAT IMPACT THE SELECTION AND ESTABLISHMENT OF THE ISO/TS 16949 MANAGEMENT SYSTEM: THE CASE OF THE AUTO PARTS INDUSTRY SECTOR IN BOGOTA

Nelson Yepes González¹, Esperanza López Castaño², Constanza Quintero Guzmán³,
John Jairo González Bulla⁴

Fecha de recepción: 16 de julio de 2013

Fecha de aprobación: 21 de abril de 2014

Referencia: N. Yepes González, E. López Castaño, C. Quintero Guzmán, J.J. González Bulla. (2014). Factores que impactan en la selección e implantación del sistema de gestión ISO/TS 16949: Caso del Sector Industrial de Autopartes de la ciudad de Bogotá. Ciencia e Ingeniería Neogranadina, 24 (1), pp. 143 - 162.

RESUMEN

Mediante la aplicación de la norma ISO/TS 16949, los fabricantes de automóviles ofrecen productos de calidad y mejoran los servicios ofrecidos a los clientes. Desde sus inicios de introducción, TS 16949 ha encontrado éxito dentro de la industria por la unificación y armonización con otras normas existentes. El presente artículo es un estudio empírico que se realizó mediante encuesta a 65 empresas de la industria autopartista en la ciudad de Bogotá (Colombia) y que permitió determinar cómo se encuentra el estado de aplicación del estándar internacional, e identificar que los factores con incidencia que impactan en la aplicabilidad de la norma son la poca exigencia de los clientes, la falta de asesoría que reciben las empresas y el poco interés de los empresarios. El estudio pone de manifiesto la necesidad de realizar una mayor apropiación de la norma de calidad en las microempresas y pequeñas empresas con la finalidad de fortalecer su adopción para la mejora de la calidad de productos y servicios del sector automotor.

Palabras clave: calidad, aseguramiento, automotriz, TLC, Sistema de Gestión de Calidad (SGC), ISO/TS16949.

1. Ingeniero Industrial, Especialista en Gerencia Financiera, Máster en Diseño, Dirección y Gestión de Proyectos, neyepes@uan-edu.co, Docente Facultad de Ingeniería Industrial, Universidad Antonio Nariño, Bogotá, Colombia.

2. Ingeniera industrial, Especialista en Negocios Internacionales, Máster en Gestión Integrada: Medio Ambiente, Calidad y Prevención, coordinador.industrial@uan.edu.co, Docente Facultad de Ingeniería Industrial, Universidad Antonio Nariño, Bogotá, Colombia.

3. Matemático, Magister en Ciencias Matemáticas, constanza.quintero@uan.edu.co, Docente Especialización en Actuaría, Universidad Antonio Nariño, Bogotá, Colombia.

4. Ingeniero Industrial, Especialista en Gerencia de Producción, john.gonzalez@uan.edu.co, Docente Facultad de Ingeniería Industrial, Universidad Antonio Nariño, Bogotá, Colombia.

