



**HAL**  
open science

## Hacia el uso de sistemas de recomendación en sistemas de alta variabilidad

Jorge L. Rodas, Javier Olivares, José Angel Galindo Duarte, David Benavides

► **To cite this version:**

Jorge L. Rodas, Javier Olivares, José Angel Galindo Duarte, David Benavides. Hacia el uso de sistemas de recomendación en sistemas de alta variabilidad. CEDI 2016, Sep 2016, Salamanca, España. hal-01342353

**HAL Id: hal-01342353**

**<https://inria.hal.science/hal-01342353>**

Submitted on 5 Jul 2016

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Hacia el uso de sistemas de recomendación en sistemas de alta variabilidad

Jorge L. Rodas<sup>1</sup>, Javier Olivares<sup>2</sup>, José A. Galindo<sup>2</sup>, and David Benavides<sup>3</sup>

<sup>1</sup> University of Milagro, Ecuador . jrodass@unemi.edu.ec

<sup>2</sup> Inria - Rennes, France . {javier.olivares,jagalindo}@inria.fr

<sup>3</sup> University of Seville, Spain . benavides@us.es

**Resumen** Los sistemas de alta variabilidad son sistemas de software que describen una gran cantidad de configuraciones. Existen sistemas de alta variabilidad que representan miles de productos. Manejar la variabilidad presente en estos sistemas es costoso y en muchos casos suele ser complicado. En la actualidad hemos visto en en la industria un notable crecimiento de los sistemas de recomendación en muchos ámbitos, como el comercio electrónico, publicidad online, entre otros. Un sistema de recomendación es un agente de software que permite hacer predicciones de una serie de productos para que se adapten mejor a las necesidades o gustos de un usuario. En este artículo de prospección proponemos la fusión de estos dos campos de la ingeniería para mejorar distintas facetas dentro de la gestión de los sistemas de alta variabilidad.

**Keywords:** Feature models, recommender systems, variability intensive systems

## 1. Introducción

Los sistemas de alta variabilidad son sistemas de software cuyo comportamiento puede ser personalizado de acuerdo con las necesidades específicas de un contexto particular [1]. Un sistema de alta variabilidad puede ser representado por un modelo de características que define el número de combinaciones posibles para las configuraciones derivadas del mismo. Esta complejidad hace que el análisis y mejora de dichos sistemas de una forma manual sea una actividad costosa y propensa a errores. Para aliviar este problema se han propuesto múltiples técnicas que permiten un análisis automático de los sistemas de alta variabilidad [2]. De hecho, en la industria podemos encontrar varios ejemplos de dichos modelos que representan la variabilidad de estos sistemas en entornos reales, como el ecosistema de dispositivos móviles [6] o los sistemas de gestión de precios en la nube (cloud-price management system)[7] que describen cientos de configuraciones diferentes.

Por otra parte, en la industria encontramos los sistemas de recomendación. Un sistema de recomendación tiene como objetivo recomendar a los usuarios los productos más adecuados de acuerdo a su perfil de gustos. Normalmente son usados para sugerir los productos que mejor se adaptan a un usuario o a un tipo

de usuario, satisfaciendo sus deseos y necesidades [4]. Actualmente, estos sistemas se aplican con éxito en diferentes entornos de comercio electrónico, como por ejemplo, la recomendación de noticias, películas, música, libros, entretenimiento, entre otros.

En este artículo, vislumbramos el uso de sistemas de recomendación para las configuraciones de distintos productos así como de las características de una determinada configuración de producto, el testing de configuraciones propensas a errores y el diagnóstico personalizado. La sección 2 muestra algunos antecedentes para comprender el alcance de la propuesta. La sección 3, presenta algunas de las posibles aplicaciones de los sistemas de recomendación en el contexto de los sistemas de alta variabilidad y finalmente, en la sección 4 se concluye el trabajo.


## 2. Antecedentes

Un sistema de recomendación se define como un sistema que guía a los usuarios de forma personalizada en la búsqueda de productos interesantes o útiles dentro de un gran conjunto de posibilidades a elegir. En el mercado existen experiencias prácticas exitosas de la implementación de las tecnologías de recomendación en contextos de comercio electrónico, como los casos de *Amazon* [9] y *Netflix* [11], los mismos que han contribuido al desarrollo de sistemas de recomendación en nuevos campos de aplicación. En [3,4] se describen en detalle variadas aplicaciones que emplean sistemas de recomendación.

Los sistemas de recomendación se dividen en dos grupos según el método de filtrado utilizado para la generación de las recomendaciones: sistemas colaborativos y sistemas basados en contenido. Los sistemas de filtrado colaborativo [8,9] se basan en el concepto de análisis de perfiles de usuarios, en donde las recomendaciones se generan en base a los gustos de usuarios con preferencias similares. Por ejemplo, en *Movielens* (<https://movielens.org/>), un usuario que ha evaluado una serie de películas, recibirá recomendaciones de otros usuarios que hayan evaluado las mismas películas o al menos una gran parte de ellas, es decir, de aquellos usuarios con intereses similares. Los sistemas de filtrado basados en el contenido [10] son aquellos en que el usuario recibe recomendaciones basadas en sus propios gustos. En este tipo de sistemas el foco de la predicción está enmarcado en las características del perfil de usuario (para un producto se consideraría características como el precio, marca, categoría, entre otros) para hacer las recomendaciones. A modo de ejemplo, un usuario de *Amazon.com* a quién le gusta los libros de fantasía, recibirá nuevas recomendaciones de libros de esa categoría.

## 3. Explorando la aplicabilidad de los sistemas de recomendación

En esta sección exploramos algunas de las tareas de gestión de sistemas de alta variabilidad que podrían beneficiarse del uso de sistemas de recomendación. Para hacer más comprensible la lectura de este artículo usaremos como ejemplo un pequeño modelo de características. En los casos que se detallan a continuación, llamaremos usuario al ingeniero de pruebas y personal de operación dentro de un modelo de negocio.



**Figura 1.** Modelo de características simplificado que describe la plataforma Android

**Recomendación de configuraciones:** Probablemente sea la aplicación más directa de los sistemas de recomendación. Consiste simplemente en recomendar productos dependiendo de configuraciones previas de otros usuarios. Por ejemplo, en la figura 1, si otros usuarios que configuraron el producto *P1:Android, Wifi, Procesador ARM*, también configuraron el producto *P2:Android, Wifi, Procesador X86*, P2 será recomendado a los que seleccionaron P1. Estas recomendaciones también se podrían realizar mediante filtros por contenido usando distintas funciones de proximidad entre características.

**Recomendación de características:** Este segundo caso de aplicación es similar al primero, no obstante el sistema de recomendación tomaría parte durante la configuración de un producto. Es decir, se encargaría de recomendar las características más seleccionadas por otros usuarios que ya han seleccionado la configuración parcial actual. Por ejemplo, si un usuario ha seleccionado las características *Wifi* y *bluetooth*, se le recomendaría seleccionar *Pantalla*, *Procesador ARM* o *Procesador X86*.

**Recomendación de configuraciones para testing:** Este último caso de aplicabilidad, representa un escenario muy interesante para los sistemas de recomendación. En este caso lo que se persigue es la recomendación de los productos que sean más susceptibles de tener errores. Para esto, partimos de la hipótesis de que los productos con menor valoración por parte de los usuarios finales, son aquellos con tendencia a contener más errores. Entonces, a partir de este conjunto de valoraciones sobre configuraciones en un modelo de características y el uso de algoritmos de filtrado colaborativo, podríamos recomendar al ingeniero de pruebas, una lista con los productos más óptimos para el testing.

**Recomendación basado en el diagnóstico personalizado:** Una de las posibles aplicaciones en el contexto de los sistemas de alta variabilidad es en la actividad de explicación de errores. Actualmente, la mayoría de las propuestas existentes para explicar errores no permiten optimizar el resultado de los mismos. Éstos tienden a mostrar la explicación mínima (aquella que requiere del menor número de cambios para solucionar el error). No obstante, esta explicación mínima no siempre es la más interesante [5]. Entendemos que mediante el uso de sistemas de recomendación se podrían obtener aquellas explicaciones que ayuden de una manera óptima al modelador del sistema de variabilidad.

## 4. Conclusiones

En este artículo de prospección proponemos el uso de sistemas de recomendación para la mejora de sistemas de alta variabilidad en casos prácticos concretos de aplicación. Para el proceso de pruebas se emplearán reportes de usuario tales como los reportes de errores (ingenieros de pruebas) o valoraciones (usuarios

finales) extraídas de bug-trackers, tiendas de apps u otros. Esta información permitirá construir un ambiente de pruebas y ejecutar experimentos que validen la propuesta. Para evaluar la propuesta se tiene contemplado tomar un conjunto de datos y contrastar los resultados obtenidos por el sistema de recomendación versus los obtenidos aplicando un mecanismo manual.

Teniendo en cuenta la importancia de los sistemas de recomendación en la actualidad, y las múltiples líneas de investigación generadas en el área, nuestros trabajos futuros pretenden abordar los siguientes temas:

- Estudiar otros métodos de ponderación de características para los algoritmos de recomendación que permitan descubrir interacciones entre varias características de acuerdo a la valoración que otorga el usuario a los productos.
- Combinar los métodos empleados en los casos presentados en esta propuesta con otros métodos de recomendación con el objetivo de mejorar las recomendaciones que se otorga al usuario (ingeniero de pruebas o usuario final).

## Referencias

1. Muhammad Ali Babar, Lianping Chen, and Forrest Shull. Managing variability in software product lines. *Software, IEEE*, 27(3):89–91, 2010.
2. David Benavides, Sergio Segura, and Antonio Ruiz-Cortés. Automated analysis of feature models 20 years later: A literature review. *Information Systems*, 35(6):615–636, 2010.
3. Jesus Bobadilla, Antonio Hernando, Fernando Ortega, and Jesus Bernal. A framework for collaborative filtering recommender systems. *Expert Systems with Applications*, 38(12):14609 – 14623, 2011.
4. Jesús Bobadilla, Fernando Ortega, Antonio Hernando, and Abraham Gutiérrez. Recommender systems survey. *Knowledge-Based Systems*, 46:109–132, 2013.
5. Alexander Felfernig, Gerhard Friedrich, Monika Schubert, Monika Mandl, Markus Mairitsch, and Erich Teppan. Plausible repairs for inconsistent requirements. In *Proceedings of the 21st International Joint Conference on Artificial Intelligence, IJCAI'09*, pages 791–796, San Francisco, CA, USA, 2009. Morgan Kaufmann Publishers Inc.
6. José A Galindo, Hamilton Turner, David Benavides, and Jules White. Testing variability-intensive systems using automated analysis: an application to android. *Software Quality Journal*, pages 1–41, 2014.
7. Jesús García-Galán, Omer F. Rana, Pablo Trinidad, and Antonio Ruiz-Cortés. Migrating to the cloud: a software product line based analysis. In *CLOSER*, 2013.
8. Joseph A Konstan, Bradley N Miller, David Maltz, Jonathan L Herlocker, Lee R Gordon, and John Riedl. GroupLens: applying collaborative filtering to usenet news. *Communications of the ACM*, 40(3):77–87, 1997.
9. Greg Linden, Brent Smith, and Jeremy York. Amazon. com recommendations: Item-to-item collaborative filtering. *Internet Computing, IEEE*, 7(1):76–80, 2003.
10. Michael Pazzani and Daniel Billsus. Learning and revising user profiles: The identification of interesting web sites. *Machine learning*, 27(3):313–331, 1997.
11. Alex Tuzhilin, Yehuda Koren, Jim Bennett, Charles Elkan, and Daniel Lemire. Large-scale recommender systems and the netflix prize competition. In *KDD Proceedings*, 2008.