

# Uso de Modelos de Markov para Recomendación de Actividades en la Hipermedia Adaptativa

Estefanía Martín<sup>1</sup>

<sup>1</sup> Lenguajes y Sistemas Informáticos I  
Universidad Rey Juan Carlos  
c/Tulipán s/n, Móstoles, Madrid, 28933, Spain  
estefania.martin@urjc.es

**Resumen.** La creación y configuración de entornos adaptativos móviles que son capaces de recomendar distinto tipo de actividades, es una labor tediosa y complicada. Sería interesante poder considerar información sobre la interacción previa de otros usuarios con los entornos creados, de tal manera que se puedan sugerir recomendaciones a un determinado usuario basadas en las acciones de otros usuarios con características similares en situaciones semejantes. De este modo, se podría utilizar directamente esta información, minimizando el proceso de especificación criterios de recomendación. Este trabajo presenta el uso de modelos de Markov para la recomendación de actividades dentro de los sistemas hipermedia adaptativos, en concreto, la incorporación de estos modelos al sistema de recomendación CoMoLE (*'Context-based adaptive Mobile Learning Environment'*).

**Palabras clave:** Hipermedia Adaptativa, Sistemas de Recomendación, Markov.

## 1 Motivación

Internet es una fuente de información para millones de personas que utilizan la Web con distintos propósitos ya sean profesionales o personales (entretenimiento, información cultural, aprendizaje, etc.). Gracias al desarrollo de las tecnologías inalámbricas y a la aparición de los dispositivos móviles, Internet provee una gran cantidad de información heterogénea. Esta información es accesible desde cualquier lugar y en cualquier momento utilizando distinto tipo de dispositivos.

No todos los usuarios tienen los mismos objetivos, intereses o necesidades. Es un hecho conocido que aspectos como la experiencia previa, los objetivos, el tiempo disponible, las preferencias o la personalidad, son factores que pueden influir en la forma de interacción con la información. En este sentido, no toda la información es adecuada para todo el mundo. Por tanto, surge la necesidad de adaptar la información presentada a cada usuario teniendo en cuenta sus necesidades personales, comportamiento mientras se encuentra interactuando con el entorno y contexto en el que se encuentra. Con este objetivo surgió la Hipermedia Adaptativa a principios de los años 90. Brusilovsky presentó la primera clasificación de métodos y técnicas de adaptación en 1996 [1]. En esta clasificación se consideran principalmente dos niveles

de adaptación: adaptación a nivel de contenidos y adaptación a nivel de navegación. Los sistemas de recomendación son un tipo concreto de sistemas adaptativos, los cuáles se centran en modelar los intereses de los usuarios y sus preferencias [2]. Un sistema de recomendación es capaz de producir recomendaciones o guiar al usuario de una forma personalizada a través de objetos que pueden ser interesantes y útiles dentro de un gran espacio de opciones (p.e. películas, música, libros, imágenes y páginas Web entre otros). En concreto, los sistemas de recomendación contienen: i) información sobre la experiencia previa de los usuarios que le permite al sistema de recomendación realizar sugerencias, ii) datos de entrada que le permiten al usuario poder comunicarse con el sistema para que se le ofrezca una recomendación, y iii) un algoritmo que combine la información sobre la experiencia previa y los datos de entrada suministrados por el usuario con el objetivo de realizar recomendaciones personalizadas. Un sistema de recomendación suele combinar las características del usuario con las características más relevantes a la hora de realizar sugerencias.

Burke presentó una revisión de las diferentes técnicas de recomendación existentes para realizar sugerencias adecuadas a los usuarios en 2002 [3]. Entre estas técnicas se encuentran el filtrado colaborativo, la recomendación basada en contenidos, la recomendación basada en el conocimiento, las técnicas de recomendación demográficas, etc. Hoy en día, el filtrado colaborativo es una de las técnicas más utilizadas por los sistemas de recomendación. Esta técnica sugiere distintos elementos teniendo en cuenta las características de los usuarios y las sugerencias, ya sean implícitas o explícitas, de otros usuarios con características o intereses similares. Este tipo de recomendación funciona mejor cuando el usuario se encuentra rodeado de usuarios con intereses similares. Por ejemplo, LastFM [4] es un sistema de recomendación de música que sugiere diferentes canciones dependiendo de los intereses de los usuarios y de las valoraciones de otros usuarios con preferencias similares, utiliza el filtrado colaborativo. En el área educativa, el filtrado colaborativo se ha utilizado para ofrecer sugerencias sobre la guía de navegación dentro del sistema Educo [5]. Otra técnica de recomendación es la que se basa en los contenidos. Tiene en cuenta las características de los objetos a recomendar, las preferencias de los usuarios y las relaciones entre ellos. Por ejemplo, el motor de búsqueda del navegador Web de Google utiliza esta técnica para deducir lo que el usuario está buscando a partir de las palabras clave de la consulta de búsqueda.

Cada una de las técnicas de recomendación tiene limitaciones, tales como el conocido problema del 'inicio congelado' para sistemas que utilizan filtrado colaborativo y sistemas que utilizan la técnica de recomendación basada en contenidos. Este problema ocurre al comenzar la utilización de este tipo de sistemas. Al inicio, existe muy poca información y por tanto no se puede efectuar recomendaciones con precisión. Por este motivo, surgen los sistemas de recomendación híbridos que combinan varias técnicas de recomendación de forma conjunta para conseguir que se complementen entre sí. Por ejemplo, Wang y Li [6] presentan un sistema Web que realiza sugerencias personalizadas y que combina las técnicas del filtrado colaborativo y la recomendación basada en contenidos.

Muchos sistemas de recomendación que utilizan la técnica de filtrado colaborativo están basados en modelos de Markov para predecir el comportamiento del usuario [7]. Un modelo de Markov de primer orden está definido por un conjunto de estados y de probabilidades de salto entre estados. En cada paso, el sistema podría cambiar del

estado actual a otro estado (o permanecer en el mismo estado) dependiendo de una determinada probabilidad. Los cambios de estados se llaman transiciones, y las probabilidades asociadas con estos cambios entre estados son las llamadas probabilidades de transición. En un modelo de Markov de primer orden, los estados son visibles para el observador y las probabilidades de transición entre estados son los parámetros. Los modelos ocultos de Markov contienen dos tipos de variables: estados y observaciones. En estos modelos, los estados no son visibles directamente. Sin embargo, las variables que tienen influencia en cada estado sí son visibles.

Los modelos de Markov han sido utilizados para modelar muchos procesos secuenciales en diferentes áreas tales como gestión de ficheros históricos, biología, matemáticas, física, reconocimiento de voz, procesamiento del lenguaje natural, economía, composición de música, robótica o aplicaciones de Internet tales como '*PageRank*', unos algoritmos que ordenan los resultados de una consulta realizada con el motor de búsqueda de Google [8].

El uso de modelos de Markov permite predecir comportamientos de un usuario y realizarle sugerencias dependiendo de sus características e intereses y de las características e intereses de usuarios similares. Algunos sistemas de recomendación que utilizan modelos de Markov son PROTEUS [9] y el presentado en [10]. PROTEUS es un sistema que permite personalizar sitios Web teniendo en cuenta los patrones de navegación de los usuarios. Su principal objetivo es reducir el tiempo y el esfuerzo que los usuarios pasan buscando información que les pueda ser útil. Este sistema intenta predecir los caminos más cortos entre distintas páginas Web. La adaptación de este sistema se realiza en dos pasos: i) construcción del modelo de usuario con la información almacenada en los ficheros históricos del sistema y, ii) selección del mejor tipo de adaptación (inclusión de enlaces entre páginas Web, ordenación de los elementos mostrados en una página Web, etc.) dependiendo del modelo de usuario construido en el primer apartado. Kurian et al. presentan un sistema hipermedia semiautomático para la autoría de entornos adaptativos. Este sistema sugiere determinados objetos a los diseñadores del entorno adaptativo, e incluye información semántica relacionada con el objeto actual. Para realizar la recomendación, utiliza modelos ocultos de Markov basados en la información almacenada en los ficheros históricos del propio sistema.

Uno de los principales problemas de los sistemas adaptativos es el proceso de creación de nuevos entornos, sobre todo, para usuarios no expertos. En los entornos adaptativos el diseñador debe especificar los rasgos de adaptación, crear diferentes actividades, proveer distintas versiones de los contenidos multimedia para cada actividad, e incluir criterios de adaptación para recomendar las actividades y contenidos más adecuados para un determinado usuario. Estas tareas son complejas y tediosas para los diseñadores, quienes pueden no poseer suficientes conocimientos técnicos necesarios para desarrollar este tipo de entornos adaptativos, o incluso no disponer de demasiado tiempo para crearlos. Por tanto, es necesario proveer soluciones transparentes que les ayuden a realizar la adaptación de actividades (enlaces y contenidos) de una forma sencilla. Sería interesante poder combinar criterios de adaptación especificados por expertos con recomendaciones basadas en la información de las interacciones previas de otros usuarios. De esta forma, la cantidad de tiempo y esfuerzo dedicado a la definición y construcción de estos entornos adaptativos disminuiría considerablemente.

El trabajo descrito en este artículo se centra en la utilización de modelos de Markov para ofrecer recomendaciones basadas en información sobre las interacciones previas de otros usuarios. El objetivo es ayudar a los profesores en el proceso de creación de entornos adaptativos donde los usuarios realizan actividades utilizando diferentes dispositivos. En concreto, se presenta la incorporación de modelos de Markov al sistema CoMoLE (“*Context-based adaptive Mobile Learning Environment*”), un sistema de recomendación de actividades que tiene en cuenta las características personales de los usuarios, su comportamiento mientras interactúan con el entorno y el contexto actual. CoMoLE permite combinar la especificación de diferentes criterios de recomendación definidos en términos de reglas de adaptación con el uso de la información previa almacenada en el sistema para ofrecer recomendaciones basadas en datos de otros usuarios. En este sentido, los diseñadores de nuevos entornos adaptativos dentro del sistema CoMoLE podrían decidir utilizar solamente la información de las interacciones previas de usuarios similares y no tener que especificar ningún criterio de adaptación, o por el contrario, combinar ambos tipos de recomendación.

El artículo se estructura como sigue: la sección 2 detalla el funcionamiento del mecanismo de recomendación del sistema CoMoLE detallando la inclusión de modelos de Markov; la sección 3 presenta la implementación de este mecanismo en el sistema CoMoLE; y por último, se presentan las conclusiones y el trabajo futuro.

## **2 Mecanismo de recomendación**

El objetivo del mecanismo de recomendación presentado en este trabajo es sugerir las actividades más adecuadas para cada usuario dependiendo de su situación particular, considerando sus características personales (por ejemplo, nivel de conocimientos, idioma o estilo de aprendizaje), acciones mientras se encuentra interactuando con el entorno (por ejemplo, actividades realizadas, resultados obtenidos en los ejercicios) y su contexto concreto (localización física, tiempo disponible y dispositivo utilizado).

Para poder realizar la recomendación y adaptación de actividades y espacios de trabajo a distintos usuarios es necesario almacenar información sobre: i) los propios usuarios, ii) las actividades a realizar, iii) los contenidos multimedia asociados, y iv) los criterios para recomendar y adaptar los distintos elementos. Esta información constituye el modelo de usuario y el modelo del dominio.

Una limitación existente actualmente en el uso de entornos adaptativos es la dificultad de creación de los mismos. Cuanto más rico sea un entorno adaptativo, más complejo será especificar su comportamiento. Para agilizar la creación de estos entornos, el mecanismo de recomendación se estructura en dos fases: recomendación basada en reglas de adaptación y recomendación basada en información previa de otros usuarios. Por un lado, la etapa de recomendación basada en reglas de adaptación procesa criterios concretos que el diseñador del entorno ha especificado para adaptar tanto las actividades como los contenidos que se presentarán al usuario. Por otro lado, la fase de recomendación basada en información previa de otros usuarios, realiza sugerencias en base a un análisis de las interacciones de otros usuarios.

## **2.1 Recomendación basada en reglas de adaptación**

Las reglas de adaptación especifican criterios concretos para recomendar distintas actividades a distintos usuarios teniendo en cuenta los rasgos definidos en el modelo de usuario y las características de las actividades a realizar.

Estas reglas de adaptación permiten: i) definir qué actividades van a formar parte de una actividad compuesta, así como las relaciones que existen entre estas subactividades; ii) especificar qué tipos de actividades deben proponerse o no en contextos concretos a determinados tipos de estudiantes; iii) asociar a actividades concretas requisitos relacionados con el contexto del usuario; y iv) establecer prerrequisitos entre actividades, de modo que una actividad no se proponga si no se ha realizado antes otra. Cada una de estas posibilidades de recomendación se encuentra representada por un tipo distinto de regla: reglas estructurales, filtros generales de contexto y reglas de requisitos individuales.

Las reglas de recomendación pueden tener asociadas condiciones de activación, relacionadas con información sobre los usuarios. Si una regla no tiene condición de activación se aplicará automáticamente. En caso contrario, es necesario que la condición se satisfaga para que la regla se active. Todos los tipos de reglas de recomendación pueden tener condiciones de activación simples o compuestas. Una condición está definida por el nombre de un rasgo de adaptación y un valor con el que se comparará, a través de un operador de relación. Se puede encontrar información más detallada sobre el la recomendación basada en reglas de adaptación en [11].

## **2.2 Recomendación basada en información de otros usuarios**

En determinadas ocasiones, puede que no exista información sobre la adecuación de una actividad para un usuario concreto que se encuentra en un contexto específico. Es decir, el diseñador del entorno no definió reglas de adaptación relacionadas con esa actividad. En este caso, se pueden realizar recomendaciones basadas en la información de otros usuarios con características similares. Por ejemplo, supongamos que existe una determinada actividad 'A' de la que no se tiene ningún tipo de información sobre su adecuación para estudiantes sin conocimientos previos. Sin embargo, se conoce que el 75% de los usuarios sin conocimientos previos realizaron dicha actividad después de realizar la actividad 'B'. En esta situación, si un usuario de este tipo acaba de finalizar la actividad 'B' y, al comprobar si 'A' debe ser recomendada o no, no se encuentra información específica definida por el creador del entorno sobre su adecuación, parece lógico recomendarle dicha actividad, ya que la mayoría de los usuarios de esta clase realizaron estas dos actividades en ese orden.

Evidentemente, para poder ofrecer este tipo de recomendaciones basadas en las acciones previas de otros usuarios con características y contextos similares, es necesario tener y tratar la información de las interacciones previas con el entorno.

La fase de recomendación basada en información de otros usuarios utiliza grafos que representan secuencias de actividades realizadas por distintos tipos de usuarios: los nodos representan las propias actividades, y los arcos las secuencias seguidas, incluyendo en cada arco la probabilidad de realizar una actividad después de haber finalizado otra. Así, para decidir si una actividad será recomendada a un usuario con

ciertas características en un contexto determinado, se consultará el grafo correspondiente con las secuencias de actividades realizadas por usuarios con características y contextos similares. Estos grafos deben construirse previamente.

El primer paso para la creación de estos grafos de secuencias, consiste en realizar una clasificación de usuarios en función de los rasgos de adaptación que se tienen en cuenta en el entorno. Un usuario está definido por un vector de atributos, que puede incluir tanto rasgos personales como características de su contexto. Cada atributo del vector tendrá asignado su valor para ese usuario. En función de los posibles valores para cada atributo, se obtiene un conjunto con todas las clases de usuarios. Por ejemplo, si consideramos un entorno en el que se tienen en cuenta la dimensión secuencial-global de los estilos de aprendizaje de los alumnos y el dispositivo que utilizan para realizar actividades de ese entorno, distinguiendo entre ordenador personal o portátil y dispositivo móvil (PDA o teléfono móvil); tenemos cuatro posibles clases de usuario: estudiante secuencial utilizando un ordenador fijo o portátil (tipo 1), estudiante secuencial utilizando una PDA o teléfono móvil (tipo 2), estudiante global utilizando un ordenador (tipo 3) y estudiante global utilizando una PDA (tipo 4). En el caso de atributos numéricos continuos (como, por ejemplo, el tiempo disponible), los valores posibles son infinitos. Por este motivo, se ha decidido dividir sus posibles valores en rangos para poder realizar esta clasificación.

Para cada clase de usuario, se puede obtener un recorrido de actividades que indica la probabilidad de realización de una actividad después de haber finalizado otra. El recorrido de actividades para cada clase se obtiene analizando el orden en el que usuarios de esta clase realizaron previamente las actividades del conjunto. Cada recorrido contiene información sobre las actividades que forman parte del conjunto y cuántos usuarios realizaron una actividad después de otra. En esta propuesta, los recorridos de actividades se representan utilizando un modelo de Markov, donde los estados representan las actividades del entorno y los enlaces entre las mismas indican la probabilidad de que un usuario realice la actividad en un momento determinado.

Una vez obtenidos los recorridos para cada clase de usuario, se puede decidir si se recomienda una actividad, teniendo en cuenta los siguientes aspectos:

- El tipo de usuario involucrado.
- La última actividad realizada (actividad origen).
- La actividad sobre la que se desea obtener información (actividad destino).
- Los recorridos entre actividades realizados por usuarios similares.
- La relación que existe entre las probabilidades de transición desde la actividad origen a cada una de las posibles actividades destino.

La recomendación sobre una determinada actividad se realiza si se puede sugerir con suficiente confianza. Se considera que existe suficiente confianza sobre una transición cuando la diferencia entre la probabilidad de transición de la actividad origen a la actividad destino (de la que se desea obtener información), y el resto de las probabilidades de transición entre la actividad origen y las demás actividades que los usuarios realizaron desde ésta (excluyendo la actividad destino), es superior a un 30%. En este caso, la actividad destino se anota como recomendada para ese usuario. Si no se cumple esta condición no se realiza ninguna acción, es decir, la actividad no se recomienda especialmente ni tampoco se impide su realización ya que no existe información suficiente sobre su adecuación para el usuario.

Con el fin de ilustrar el funcionamiento de esta fase del mecanismo de recomendación, se presenta un ejemplo sobre una asignatura de “Informática General”. Los profesores han puesto a disposición de los estudiantes un entorno de aprendizaje ubicuo donde deberán realizar distintas actividades relacionadas con el “Álgebra de Boole”:

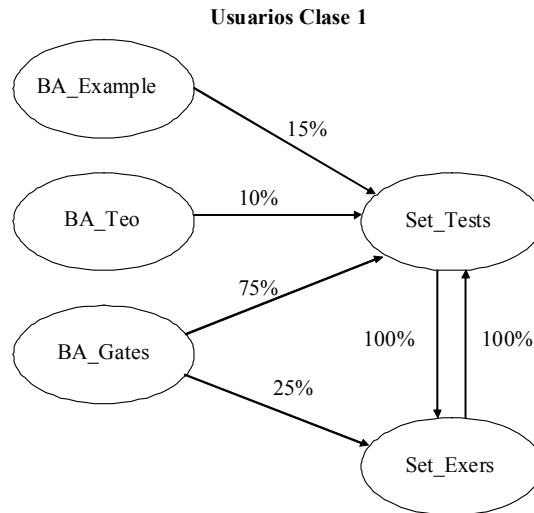
- Repasar los conceptos aprendidos hasta el momento (*Review*)
- Estudiar los conceptos básicos sobre el Álgebra de Boole (*BA\_Theo*) y las distintas operaciones booleanas (*BA\_Operations*).
- Comprender ejemplos con tablas de verdad y puertas lógicas (*BA\_Example*).
- Interactuar con ‘*applets*’ que les permitirán hacer simulaciones sobre operaciones booleanas con distintas puertas lógicas (*BA\_And*, *BA\_Or*, *BA\_Not*, *BA\_Nand*, *BA\_Xor*) y circuitos más complejos (*BA\_Circuits*).
- Realizar una colección de ejercicios tipo test (*Set\_Tests*) y de ejercicios de respuesta libre (*Set\_Exers*).

Además, los rasgos de adaptación que se tienen en cuenta en este entorno de aprendizaje son el nivel de conocimientos de los estudiantes (novato, avanzado), si los estudiantes cursan por primera vez la asignatura y el tiempo disponible (cuyos valores están agrupados en cuatro rangos: menos de 30 minutos, entre 30 minutos y una hora, entre una y dos horas y más de dos horas). De este modo, el proceso de recomendación basado en información de otros usuarios, podrá clasificar a los usuarios en 16 categorías: 2 valores del nivel de conocimiento x 2 valores de la experiencia previa x 4 valores del tiempo del que disponen los usuarios.

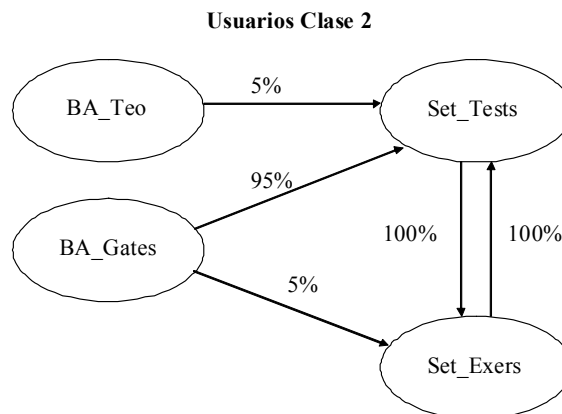
En las figuras 1 y 2 se muestran dos recorridos parciales de actividades calculados para dos de las clases de estudiantes de la asignatura de “Informática General”. En el grafo de la figura 1, se muestra parte del recorrido realizado por estudiantes que cursan por primera vez la asignatura con conocimientos avanzados y que disponen de 20 minutos para la realización de actividades (clase 1). El grafo de la figura 2 presenta parte de los recorridos para estudiantes de la clase 2, alumnos que cursan por segunda vez la materia, tienen conocimientos básicos y disponen también de veinte minutos.

Estos grafos de recorridos representa la probabilidad de que un usuario con las características de la clase asociada realice una actividad después de otra. Por ejemplo, se puede ver que para los estudiantes de clase 1, la actividad *Set\_Tests* se puede realizar después de cuatro actividades distintas: *BA\_Example*, *BA\_Theo*, *BA\_Operations* y *Set\_Exers* (véase la figura 1). En el caso de finalizar la actividad *BA\_Gates*, el 75% de las ocasiones los usuarios decidieron realizar a continuación la actividad *Set\_Tests* y el restante 25% hicieron la actividad *Set\_Exers*. Además, después de finalizar la actividad *Set\_Tests* los usuarios siempre realizan la actividad *Set\_Exers*. Lo mismo ocurre en orden inverso entre estas dos últimas actividades.

En el caso de usuarios de la clase 2 (ver figura 2), la relación entre los ejercicios *Set\_Tests* y *Set\_Exers* es la misma que para los usuarios de la clase 1 (si se ha decidido realizar cualquiera de las dos actividades, a continuación, el usuario hará la otra). Sin embargo, se puede observar que el porcentaje de usuarios de esta clase que inicia la actividad *Set\_Tests* después de la actividad *BA\_Theo* baja a un 5% frente a los usuarios de la clase 1, cuyo porcentaje era del 10%. Ningún usuario de la clase 2 ha realizado la actividad *Set\_Tests* después de la actividad *BA\_Example*. Por este motivo no existe esta relación en el grafo de la figura 2.



**Fig. 1.** Ejemplo de recorrido de actividades para un usuario de la clase 1.



**Fig. 2.** Ejemplo de recorrido de actividades para un usuario de la clase 2.

De acuerdo a estos datos, supongamos que un usuario de clase 1 ha finalizado las actividades BA\_Example y BA\_Theo pero todavía no ha realizado las actividades BA\_Gates, Set\_Tests y Set\_Exers. Además, el mecanismo de recomendación basado en reglas de adaptación ha anotado la actividad BA\_Gates como recomendada, pero no tiene suficiente información sobre la adecuación de recomendar las actividades Set\_Tests y Set\_Exers. En esta situación, el mecanismo de recomendación basado en la información de otros usuarios no ofrecería ninguna recomendación específica sobre la realización de ninguna de estas dos actividades, es decir, mantendría el estado de dichas actividades como disponibles. Esto se debe a que en la mayoría de las situaciones (un 75% de las ocasiones), los usuarios realizan estas dos actividades después de realizar la actividad BA\_Gates (ver grafo de recorridos de la figura 1).



Sin embargo, si el mismo usuario realiza la actividad BA\_Gates y la recomendación basada en reglas de adaptación sigue sin tener información de las actividades Set\_Tests y Set\_Exers, se sugeriría la realización de la actividad Set\_Tests ya que la mayoría de los usuarios han realizado estas actividades en este orden (un 75% en el caso de usuarios de clase 1). Si el usuario hubiera pertenecido a la clase 2, la recomendación habría sido la misma en este caso particular, ya que la probabilidad de realizar la actividad Set\_Tests después de la actividad BA\_Gates para estos usuarios es de un 95%.

### **2.3 Funcionamiento del mecanismo de recomendación**

El mecanismo de recomendación es el encargado de procesar, en tiempo real, los distintos elementos (reglas de recomendación e información sobre otros usuarios) para, en función del perfil de cada usuario, seleccionar las actividades más adecuadas dependiendo de sus características personales, de sus acciones y de su contexto particular. Para cada usuario que se encuentra interactuando con el entorno, se selecciona las actividades más adecuadas en función de la información almacenada en el modelo de usuario y el modelo del dominio. En cada paso, el mecanismo evalúa la adecuación de la realización de cada actividad por parte del usuario en su contexto particular, y anota las actividades según su grado de recomendación:

- Recomendada: los requisitos particulares y las dependencias con respecto a otras actividades se satisfacen, y además el contexto del usuario es propicio para realizar la actividad.
- No recomendada: actividad que no es recomendable proponer en ese momento porque no se satisface alguna condición relacionada con el contexto del usuario.
- Disponible: la actividad está disponible en cuanto a requisitos particulares y dependencias con otras actividades, y no se tiene información sobre si debe recomendarse en ese contexto o no.
- No disponible: alguna de las condiciones de activación de requisitos particulares para realizar la actividad o de actividades que debería haber realizado previamente para poder abordar ésta, no se satisfacen.
- Finalizada: el usuario ya ha realizado la actividad.

El funcionamiento general del mecanismo se puede ver en el esquema de la figura 3. Primeramente, el gestor de actividades extrae un listado inicial de actividades disponibles para el usuario en el entorno. Las actividades ya realizadas por el usuario se anotan como tales en dicho listado antes de procesar las reglas de recomendación. Este listado es la entrada del proceso de recomendación basado en reglas, el cual se encarga de indicar, para cada actividad, su grado de recomendación. Durante el procesamiento de las reglas de adaptación, el grado de recomendación de cada actividad se va actualizando. Cada tipo de regla se procesa por un filtro distinto, seleccionando en cada uno de ellos las actividades más adecuadas para el usuario teniendo en cuenta sus características, acciones y su contexto actual. Cada filtro genera como salida un listado intermedio de actividades anotadas que es la entrada del siguiente, hasta obtener un listado final donde las actividades están anotadas con su disponibilidad y grado de recomendación [11].

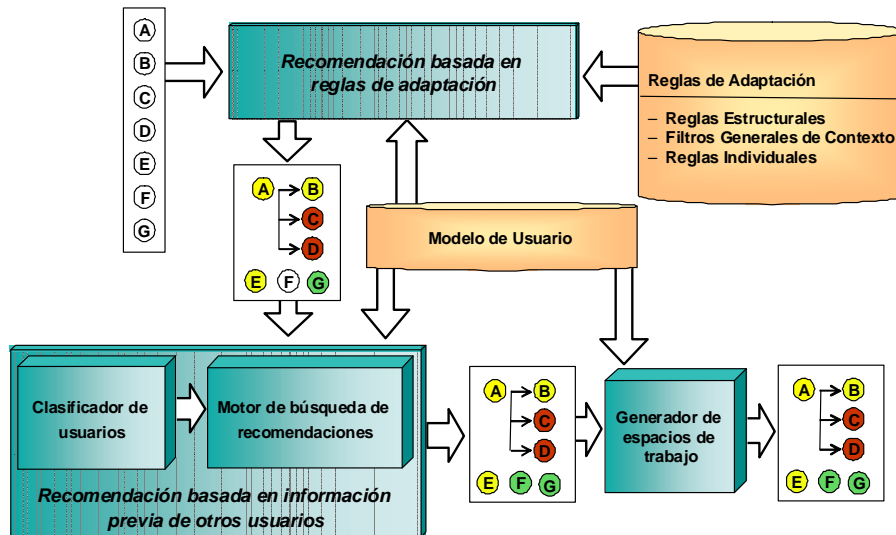


Fig. 3. Funcionamiento general del mecanismo de recomendación.

El listado de salida del proceso de recomendación basado en reglas puede contener actividades para las que no se ha encontrado información especificada en términos de reglas de adaptación sobre la adecuación de proponer estas actividades al usuario (las actividades se encuentran simplemente “disponibles”, pero ni recomendadas ni no recomendadas especialmente para ese usuario en ese contexto particular). El mecanismo de recomendación en su segunda fase realiza recomendaciones basadas en la información de usuarios similares (clases de usuarios y recorridos de actividades presentados en la sección previa). Estas recomendaciones se pueden ofrecer tanto en los casos en los que no exista información sobre ciertas actividades, como en los casos en los que el diseñador decida no especificar criterios de recomendación en forma de reglas. En caso de utilizar esta fase combinada con la fase de recomendación basada en reglas, las anotaciones realizadas en el listado de actividades al procesar las reglas se completan con decisiones de recomendación basadas en la información previa de otros usuarios con características similares teniendo en cuenta el orden en el cual realizaron las actividades. Si, por el contrario, se utiliza solamente la fase de recomendación basada en información de otros usuarios, se parte del listado inicial generado por el gestor de actividades y se anota en consecuencia.

Por último, el listado completo de actividades anotadas se envía al generador de espacios de trabajo que se encargará de generar los espacios de trabajo para la realización de las distintas actividades, seleccionando los contenidos multimedia más adecuados para cada tipo de usuario según sus características y contexto particular, y las herramientas más apropiadas para dar soporte a la realización de la actividad, también considerando las características y el contexto de los usuarios.

### 3 Implementación

El mecanismo de recomendación del apartado anterior se encuentra implementado en el sistema CoMoLE (*Context-based adaptive Mobile Learning Environment*). Cada fase del mecanismo de recomendación se encuentra implementada en un módulo independiente para permitir su utilización independiente. Este sistema integra la recomendación basada en reglas definidas por expertos con una recomendación basada en información previa de otros usuarios, por lo que puede considerarse como un sistema de recomendación híbrido. Además, gracias a este último tipo de recomendaciones, no es necesario especificar a priori ningún tipo de criterio de adaptación en términos de reglas para poder realizar recomendaciones de actividades a los usuarios del sistema.

Los detalles de la implementación de la fase de recomendación basada en reglas de adaptación se encuentran detallados en [12]. En cuanto al proceso de recomendación basado en información de otros usuarios, es necesario que el sistema tenga información previa sobre la realización de actividades de las distintas clases de usuarios. Una vez que el sistema tiene datos para analizar, se realiza una fase “*off-line*” en la que se buscan las secuencias de realización de actividades para los usuarios de cada clase. Esta información se guarda en ficheros del sistema para que, el módulo de recomendación basado en información de otros usuarios la pueda utilizar posteriormente. La figura 4 muestra las secuencias de actividades realizadas por estudiantes con estilo de aprendizaje visual, activo y sensorial de la asignatura “*Estructuras de Datos y de la Información I*” (EDII) cuando tenían disponible entre 30 minutos y una hora, y se encontraban en su casa utilizando su ordenador personal. Al comienzo del fichero aparece el número de usuarios con las mismas características personales que se encontraron en el contexto descrito anteriormente al menos en una ocasión. En este caso concreto, fueron 24 usuarios. Este número no significa que el total de estudiantes con estilo de aprendizaje visual, activo y sensorial interactuando con el entorno EDII fuera de 24, ya que el contexto de los estudiantes pudo cambiar en sucesivas sesiones con el sistema y por tanto, podría haber acciones de los mismos usuarios clasificadas en otras categorías.

A continuación, aparece el número total de actividades definidas para el entorno. En el caso concreto de EDII fueron 126 actividades, incluyendo simples y compuestas. Finalmente, se muestra información sobre las secuencias de actividades realizadas por los estudiantes clasificados en esta categoría. En cada una de las líneas se puede ver un identificador de actividad (actividad origen) seguido de pares que indican qué actividad realizaron los estudiantes después de realizar la actividad origen y cuántos estudiantes realizaron este salto o siguieron esa secuencia. Por ejemplo, después de realizar la actividad cuyo identificador es 1 (que se corresponde con la actividad que contiene ejemplos de tipo de datos atómicos, “*AtomicosEjem*” de este entorno de aprendizaje), 16 estudiantes realizaron la actividad número 2, (que se corresponde con la teoría de tipos atómicos, “*AtomicosTeo*”), y dos estudiantes realizaron la actividad número 55 (ejemplos de tipos enumerados, “*EnumEjem*”).

En este fichero, se puede observar que existen varias actividades para las que no se ha registrado secuencia alguna (la línea correspondiente contiene sólo el identificador de la actividad origen). Estas actividades se corresponden con actividades compuestas, las cuales no se han considerado en los recorridos, ya que en ambos

casos de estudio no tenían asociado ningún tipo de contenidos (sólo servían para agrupar otras actividades) y, por tanto, no se corresponden realmente con actividades que los estudiantes deban realizar.

Numero de usuarios: 24

126							
0							
1	2	16	55	2			
2	55	13	56	2			
3							
4	5	12					
5	6	12	7	1			
6	7	12					
7	8	13					
8	9	12	10	1			
9	10	12					
10	11	11	12	1			
11	12	11					
12	13	9					
13	16	8	17	1			
14							
15							
16	20	8					
17	18	1	20	1	21	7	
18	21	1	22	7			
19							
20	17	8	21	1			
21	18	7	22	2			
22	23	9					
23	33	8					
24							
25	26	6					
26	27	6	39	1			
...							

**Fig. 4.** Ejemplo de la información almacenada en ficheros correspondiente a las secuencias de actividades realizadas por un perfil determinado de usuario.

Una vez obtenidos los ficheros con las secuencias de realización de actividades para cada tipo de usuario (un fichero por clase), el módulo de recomendación basada en información de otros usuarios utiliza la información almacenada en estos ficheros para generar matrices con las probabilidades de transición entre actividades utilizando un modelo de Markov. En el ejemplo considerado en la figura 4, para la actividad “AtomicosEjem”, la probabilidad de transición de la actividad origen “AtomicosEjem” a la actividad destino “AtomicosTeo” es de un 88,88% (esta transición la llevaron a cabo 16 estudiantes de un total de 18 de este tipo concreto que realizaron la actividad origen); por su parte, la probabilidad de realizar la actividad “EnumEjem” después de la actividad “AtomicosEjem” es de un 11% (2 estudiantes de 18 en total). Si nos fijamos en los resultados obtenidos al considerar la actividad “IfTeo”, cuyo identificador es el número 17 en el fichero mostrado en la figura 5.28,

tendremos que un usuario realizó a continuación la actividad número 18 (“IfTest”), otro realizó la actividad número 20 (“SwitchTeo”), y siete estudiantes realizaron la actividad número 21 (“SwitchEjem”). En este caso, las probabilidades de transición entre la actividad “IfTeo” y las actividades “IfTest”, “SwitchEjem” y “SwitchTeo” son de 11,11%, 11,11% y 77,77%, respectivamente.

Estas probabilidades de transición son las que utiliza el módulo de recomendación basada en información de otros usuarios para efectuar las sugerencias de diversas actividades a distintos usuarios si existe un nivel de confianza suficiente para efectuar esta recomendación. El proceso de recomendación implementa el algoritmo detallado en la sección 2.2.

## 4 Conclusiones y trabajo futuro

Este artículo ha presentado la inclusión de modelos de Markov para la recomendación de actividades dentro de los sistemas hipermedia adaptativos, en concreto, la incorporación de estos modelos al sistema de recomendación CoMoLE (*‘Context-based adaptive Mobile Learning Environment’*). El objetivo de la inclusión de estos modelos, era minimizar el tiempo y el esfuerzo que los diseñadores de los entornos adaptativos le dedican a su creación y configuración. El módulo de recomendación basado en información previa de otros usuarios, hace posible que este proceso sea menos complejo para usuarios no expertos que en otros sistemas hipermedia adaptativos donde el diseñador es el responsable de especificar los criterios de adaptación para recomendar las actividades y contenidos más adecuados a cada usuario.

Además, el sistema CoMoLE permite utilizar el módulo de recomendación basado en reglas y el módulo de recomendación basado en información previa de otros usuarios de forma independiente. Esto permite que diseñadores inexpertos puedan utilizar únicamente el módulo de recomendación basado en información de otros usuarios si no quieren especificar ningún criterio de adaptación, o combinar los dos módulos. Para diseñadores inexpertos que quisieran proponer a los usuarios actividades simples sin restricciones individuales de realización, sería muy sencillo la creación de estos entornos, ya que solamente tendrían que definir unos filtros generales de contexto que especificasen qué tipos de actividades son recomendables dependiendo del contexto de los usuarios, y utilizar el módulo de recomendación basada en información de otros usuarios.

El principal problema de este módulo de recomendación es que necesita información previa de un número importante de usuarios. Además, dependiendo del número de rasgos de adaptación que se tengan en cuenta a la hora de realizar la adaptación, el número de clases de usuarios de estos entornos puede ser demasiado grande (tantas como combinaciones de los valores de las características de usuario y contextos). En este caso, sólo unas cuantas categorías tienen un número significativo de usuarios y por tanto, pueden utilizarse para poder realizar recomendaciones. Por este motivo, sería interesante poder agrupar estas clases detectando las características más relevantes y eliminar las combinaciones que surgen de los rasgos menos relevantes. De esta manera, sólo se tendrían las clases creadas a partir de las

combinaciones de las características que más influyan en la realización de las actividades. Esto repercutiría positivamente a la hora de realizar recomendaciones a los usuarios, pues se tendría información relevante con más antelación.

Por último, también se está trabajando en ofrecer la posibilidad de configurar el nivel mínimo de confianza exigido para efectuar una recomendación en el módulo de recomendación basada en información de otros usuarios.

**Agradecimientos.** Este trabajo ha sido financiado por el Ministerio de Ciencia y Educación. Número de proyecto TIN2007-64718.

## References

1. Brusilovsky, P.: Methods and techniques of adaptive hypermedia. *User Modeling and User Adapted Interaction*, vol. 6, 2-3, pp. 87-129 (1996).
2. Brusilovsky, P., Millán, E.: User Models for Adaptive Hypermedia and Adaptive Educational Systems. *The Adaptive Web: Methods and Strategies of Personalization*, Lecture Notes in Computer Science vol. 4321, pp. 3-53. Springer-Verlag (2007).
3. Burke, R.: Hybrid Recommender Systems: Survey and Experiments. *User Model and User-Adapted Interaction*, vol. 12(4), pp. 331-370. Kluwer Academic Publisher (2002).
4. LastFM, <http://www.lastfm.es/>
5. Kurhila, J., Miettinen, M., Nokelainen, P., Tirri, H.: EDUCO - A Collaborative Learning Environment Based on Social Navigation. *LNCS*, vol. 2347, pp. 242-252 (2002).
6. Wang, X., Li, B.: Intelligent Knowledge Recommendation System Based on Web Log and Cache Data. *Advances in Web Based Learning. Lecture Notes in Computer Science*, vol. 4181, pp. 48-56. Springer Berlin / Heidelberg (2006).
7. Rabiner, L.: A tutorial on Hidden Markov Models and selected applications in speech recognition. *Proceedings of IEEE*, vol. 77 (2), pp. 257-269 (1989).
8. PageRank, <http://www.google.com/patents?vid=6285999>
9. Anderson, C., Domingos, P., Weld, D.: Relational Markov models and their application to adaptive Web navigation. *Proceedings of the Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 143-152. ACM Press (2002).
10. Kurian, J.C., Barnaghi, P.M., Hartley, M.I.: Semantics-based Dynamic Hypermedia Adaptation using the Hidden Markov Model. *Proceedings of the 1st International Workshop on Semantic-Enhanced Multimedia Presentation Systems* (2006).
11. Martín, E., Carro, R.M., Rodríguez, P.: A Mechanism to Support Context-based Adaptation in M-Learning. *Innovative Approaches for Learning and Knowledge Sharing. Lecture Notes in Computer Science*, vol. 4227, pp. 302-315. Springer Berlin Heidelberg (2006).
12. Martín, E., Carro, R.M.: Supporting the Development of Mobile Adaptive Learning Environments: A case study. *IEEE Transactions on Learning Technologies*, vol. 2, no.1, pp. 23-36, Jan-March (2009).