

Considerando preferencias contextuales en sitios de educación a distancia

Victoria Eyharabide y Analía Amandi
Instituto de investigación *ISISTAN*, *UNCPBA*, Campus Universitario,
Paraje Arroyo Seco, CP B7001BBO, Tandil, Bs. As., Argentina
CONICET Consejo Nacional de Investigaciones Científicas y Técnicas.

{veyharab,amandi}@exa.unicen.edu.ar

Resumen. A fin de facilitar el aprendizaje en un sistema de educación a distancia es necesario brindar a cada estudiante asistencia personalizada según el contexto en el que se encuentra. Para lograrlo, es necesario detectar cuales son las preferencias contextuales que influyen en el accionar de un estudiante. En este artículo presentamos un caso de estudio en el que aprendemos cuál es el contexto relevante para un estudiante cuando ejecuta una determinada tarea. Los resultados experimentales obtenidos proveen evidencia de la efectividad de usar una propuesta ontológica para perfiles de usuario en sitios de educación a distancia.

Palabras clave: Perfiles de usuario, Contexto, Personalización, Educación a distancia.

1 Introducción

Los sitios de educación a distancia se están convirtiendo en un medio cada vez más utilizado para adquirir conocimiento. Estos sitios son accedidos por infinidad de personas en ambientes cada más diversos y heterogéneos. A fin de satisfacer las necesidades y objetivos particulares de cada estudiante, es necesario personalizar el sitio de educación a distancia según las preferencias y hábitos de cada persona. El soporte personalizado para estudiantes se hace cada vez más importante en ambientes web de aprendizaje dinámico [1]. Por esta razón, las técnicas de personalización en sistemas de educación a distancia es un tema que ha cobrado gran interés en los últimos años. Sin embargo, a pesar de la gran variedad de sistemas educativos desarrollados, muchos de estos sistemas poseen estrategias de personalización predefinidas y con poca capacidad de adaptación conforme se van modificando las preferencias de los estudiantes.

A fin de mejorar la personalización ofrecida a un estudiante en un sitio de educación a distancia, es necesario considerar el contexto en el que se encuentra. Por contexto entendemos las preferencias y formas de comportamiento determinadas por la situación en la que se encuentra una persona. Conocer cuál es el contexto relevante que influye en el accionar de un estudiante es de gran utilidad, ya sea para personalizar el sitio de educación a distancia o para analizar sus habilidades educativas.

No obstante, considerar contexto para personalizar sistemas de educación a distancia es un gran desafío. Al igual que otras aplicaciones de software, los sistemas web educativos están generalmente restringidos a una única estrategia de personalización. Sin embargo, no se puede asignar la misma personalización predefinida a todas las personas, ya que algunas pueden estar inmersas en varios contextos al mismo tiempo; y por lo tanto, ser contextualmente ambiguas [2]. No todos los estudiantes se comportan de la misma manera en un sitio de educación a distancia. Más aun, no todos poseen las mismas preferencias, conocimiento previo, habilidades educativas ni estilo de aprendizaje. Más aún, cada una de ellas puede variar para el mismo estudiante según el contexto en el que se encuentre. Esto significa que el sistema de educación a distancia debe personalizarse en relación a las preferencias contextuales propias de cada estudiante en particular.

En este artículo presentamos nuestra propuesta para modelar contexto en sitios de educación a distancia. En particular, detallamos un caso de estudio en el que instanciamos nuestro modelo (presentado en [3]) en el sitio de educación a distancia *SAVER*. El objetivo es incrementar aún más las capacidades de personalización de *SAVER* para modelar el contexto de los estudiantes en diferentes escenarios. Asimismo, buscamos testear la habilidad de nuestra propuesta para aprender el contexto relevante para el estudiante en situaciones concretas que se presentan al utilizar un ambiente educativo. Los resultados experimentales obtenidos proveen evidencia de la efectividad de usar una propuesta ontológica para perfiles de usuario en sitios de educación a distancia.

El artículo se encuentra estructurado de la siguiente manera. Inicialmente, en la Sección 2 se realiza un análisis de distintos trabajos relacionados que intentan mejorar la personalización de sitios de educación a distancia mediante una mejor utilización de la información contextual disponible. Luego, en la Sección 3, se presenta nuestra propuesta para aprender contexto relevante en sitios de educación a distancia. Posteriormente, en la Sección 4 se detalla el caso de estudio en el que evaluamos nuestra propuesta. Finalmente, en la Sección 5 se exponen los resultados experimentales obtenidos y en la Sección 6 se presentan las conclusiones.

2 Trabajos Relacionados sobre Contexto en Educación

Existen diversos trabajos [1], [4], [5] que consideran el uso de contexto para educación a distancia. Entre ellos se encuentra el trabajo propuesto en [6] que discute la importancia del contexto de trabajo del usuario (dado por la plataforma de usuario, la ubicación del usuario y el estado afectivo) en sistemas de educación adaptativos. Otro ejemplo es el artículo presentado en [7], donde los autores proponen una estrategia de personalización de sitios de educación a distancia basada en dos niveles: El primer nivel permite la personalización de escenarios de aprendizaje según una estrategia de personalización predefinida; mientras que el segundo nivel permite a los profesores seleccionar y combinar los parámetros de personalización para definir diferentes estrategias de personalización. Por otro lado, Lisa Fan en [1] presenta cómo realizar personalizaciones en ambientes educativos dinámicos y heterogéneos utilizando tecnologías web adaptativas.

Otro trabajo que considera ambientes educativos sensibles al contexto es el presentado en [8]. En dicho estudio, los autores intentan maximizar la eficacia de aprendizaje de los estudiantes considerando el significado de los caminos de aprendizaje y el número de visitas simultáneas a cada objeto de aprendizaje. Finalmente, el artículo presentado en [5], analiza dos estrategias para aprendizaje personalizado sensible al contexto. La primera propuesta intenta descubrir qué conocimiento está buscando el estudiante y en qué nivel. La segunda propuesta busca construir y analizar una red de usuarios con el objetivo de encontrar una lista de posibles colaboradores.

Luego de analizar diferentes trabajos relacionados, estamos en condiciones de afirmar que existen dos principales razones para modelar contexto para educación: enfocarse en la tarea educativa y la reutilización. En primer lugar, un profesor puede desconocer cuáles son las diferencias contextuales de sus alumnos. Aún cuando las conozca, él debería concentrarse en el material educativo, sin prestar atención en cómo adaptar ese material a diferentes estudiantes. En segundo lugar, el contexto puede ser el mismo para diferentes alumnos en diferentes cursos. Por lo tanto, el ambiente de aprendizaje debería proveer soporte para reutilizar esas descripciones repetitivas de contexto.

3 Aprendiendo Contexto en Sitios de Educación a Distancia

Los estudiantes se caracterizan por tener rasgos individuales diferentes. Entre esos rasgos se encuentran sus preferencias contextuales. Esto es, de acuerdo al contexto en el que se encuentren, los estudiantes se comportan de distinta manera siguiendo sus preferencias particulares. A fin de construir un perfil de usuario que contenga esas preferencias contextuales, comenzamos observando el comportamiento de cada estudiante en el sitio de educación a distancia, haciendo especial énfasis en el análisis del contexto que rodea a cada acción realizada por el estudiante.

Los estudiantes pueden realizar múltiples actividades en el sitio educativo, cada una de las cuales puede tener un propósito diferente y desarrollarse en un contexto totalmente distinto. Entre esas actividades se encuentran, por ejemplo, la lectura de material educativo, la realización de una evaluación, el intercambio de opiniones con otros estudiantes mediante el chat, el trabajo en conjunto a través de las herramientas de trabajo colaborativo, entre otras. Como se aprecia en la Figura 1 marcado con el número 1, la interacción que se lleva a cabo entre el estudiante y el ambiente educativo transcurre en un determinado contexto. Mediante el análisis de ese contexto, en esta propuesta buscamos aprender cuál es el contexto que influye para que un estudiante se comporte de una determinada manera; y posteriormente, almacenar el contexto relevante aprendido en el perfil de usuario correspondiente.

El comportamiento realizado por el estudiante, es almacenado en una base de datos junto con toda la información que caracteriza la situación en la que se encuentra dicho estudiante (Figura 1, número 2). Luego, se extrae de dicha base de datos toda la información del usuario allí almacenada y se la enriquece con información contextual proveniente tanto de: i) *ontologías de tareas* y ii) *ontologías de dominio*.

Las ontologías de tareas describen todas las posibles tareas que se pueden realizar en el sitio de educación a distancia; mientras que las ontologías de dominio (como por ejemplo, ontologías que describen aspectos culturales, educativos, tecnológicos, entre otros) aportan información contextual adicional. Siguiendo el modelo presentado en [3], cada una de esas ontologías contextuales representa una dimensión contextual diferente. Posteriormente, a partir de toda esa información disponible (base de datos + ontologías de tareas + ontologías de dominio) se genera un conjunto de *situaciones de usuario* (Figura 1, número 3). Llamamos *situación de usuario* a una N-tupla formada por una tarea ejecutada por el usuario (en este caso de estudio, un estudiante) y un conjunto de valores de atributos contextuales que describen la situación en la que se ejecutó esa tarea. Ese conjunto de situaciones de usuario constituye la entrada a nuestro algoritmo de aprendizaje (Figura 1, número 4).

El objetivo es descubrir cuál es el contexto que influye en el accionar del estudiante. Aprender cuál es el contexto relevante para un usuario a partir de la observación de las acciones que ejecuta, es principalmente un problema de inferencia bajo condiciones de incertidumbre. Por ese motivo, se desarrolló un algoritmo capaz de calcular la probabilidad de cada atributo contextual de ser relevante dada la evidencia disponible. El algoritmo, que por cuestiones de espacio no se describe en este artículo, se basa en una combinación de Reglas de Asociación, Redes de Bayes y Propagación de Activación aplicadas a Ontologías. Este algoritmo permite encontrar y actualizar dinámicamente los atributos contextuales que influyen en la ejecución de cada tarea; así como también, incorporar dinámicamente y considerar distintas relaciones entre dichos atributos contextuales. Finalmente, luego de realizar todo el proceso de aprendizaje, se obtiene como resultado final el *Perfil del Usuario* (Figura 1, número 5).

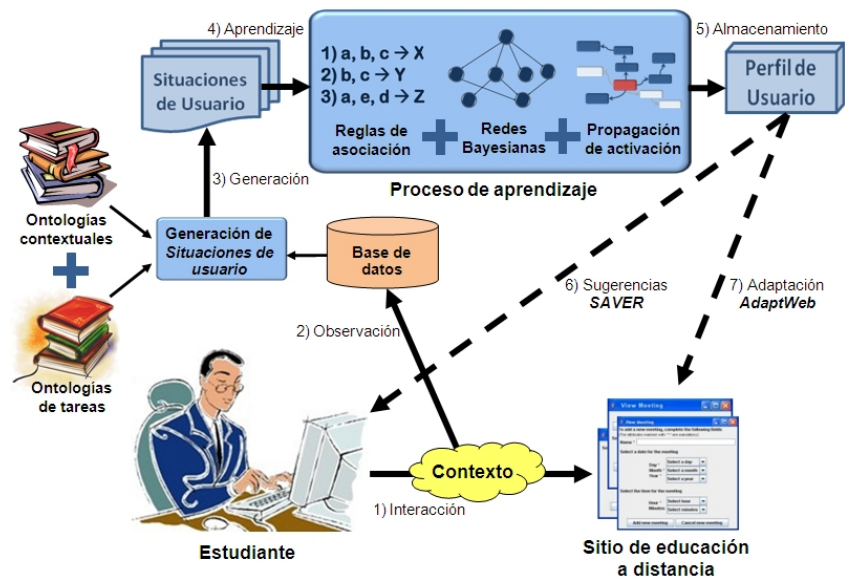


Figura 1. Construcción de perfiles de usuario en sitios de educación a distancia

Las últimas dos etapas visualizadas en la Figura 1 (representadas mediante líneas punteadas), muestran cómo el perfil de usuario aprendido puede utilizarse para personalizar los servicios brindados al estudiante. En particular, se presentan dos posibles usos del perfil. En primer lugar, una posible aplicación del perfil es la presentación de sugerencias directas al estudiante (Figura 1, número 6). Esas sugerencias estarían destinadas a mejorar su rendimiento en el sitio de educación y estarían realizadas en base a sus preferencias contextuales. Este tipo de aplicación del perfil se puede llevar a cabo, por ejemplo, en sitios como *SAVER*¹ (ver el *Caso de estudio* en la siguiente sección) donde se brinda asistencia personalizada mediante el uso de agentes personales. Actualmente, *SAVER* cuenta con *e-Teacher* [9], un agente personal que provee recomendaciones personalizadas a los estudiantes dependiendo de su perfil y su performance en *SAVER*. Se pretende extender las capacidades actuales de *e-Teacher* para enriquecer los modelos de estudiantes que construye ese agente para incorporarles los perfiles contextuales aprendidos mediante nuestra técnica.

En segundo lugar, otra posible implementación de nuestro perfil es la adaptación de la interfaz de un sitio de educación a distancia (Figura 1, número 7). Este tipo de personalización es el que se realiza en sitios como *AdaptWeb*². *AdaptWeb* es un sitio de educación a distancia que comenzó como un proyecto de investigación y actualmente está siendo utilizado de varias universidades federales brasileñas. La personalización en *AdaptWeb* se realiza mediante la adaptación del contenido, la presentación y la navegación de un curso web educativo, según un modelo de estudiante. Actualmente, en el marco del proyecto internacional *AdaptSur*³, estamos extendiendo los modelos utilizados por *AdaptWeb* para enriquecerlos con nuestra propuesta contextual. Los resultados obtenidos fueron publicados en [2].

4 Caso de Estudio: *SAVER*

A continuación se describe el caso de estudio en el que aplicamos nuestra propuesta al sitio de educación a distancia *SAVER*. En particular, se ilustra cómo es posible mejorar tanto la asistencia brindada al estudiante como la adaptación de la interfaz y contenido del sitio web a través del uso del contexto relevante almacenado en el perfil de usuario aprendido.

4.1 *SAVER*: Software de Asistencia Virtual para Educación Remota

El sistema de educación a distancia *SAVER* (Software de Asistencia Virtual para Educación Remota) es un sistema de educación Web desarrollado en la *UNICEN* (Universidad Nacional del Centro de la Provincia de Buenos Aires).

¹ *SAVER*: <http://www.e-unicen.edu.ar/>

² *AdaptWeb*: <http://sourceforge.net/projects/adaptweb>

³ *Adapt-SUR* es un proyecto internacional entre Argentina y Brasil en el marco del Programa de Cooperación Científico Tecnológica entre SECYT y CAPES – ADAPTSUR N° 042/07 (Secyt, Argentina) – 022/07 (CAPES, Brasil).

Esta herramienta para educación a distancia permite la realización de distintos cursos presentando diferentes materiales de estudio y brindando la posibilidad de realizar ejercicios para que el alumno afiance los nuevos conocimientos. Además, *SAVER* permite la carga de materiales didácticos para el desarrollo de los cursos y brinda la posibilidad de evaluar a los estudiantes a través del sistema. Asimismo, brinda una serie de herramientas como chat, foro, correo electrónico, preguntas frecuentes, archivos compartidos, espacio para trabajos colaborativos, que permiten una fluida comunicación entre los alumnos y profesores.

SAVER observa el comportamiento de cada estudiante mientras utiliza el sistema, y almacena las observaciones en una base de datos. Nosotros decidimos utilizar la información registrada en dicha base de datos debido a que en ella se encuentra información de varios cursos realizados en *SAVER* y que se han vuelto a dictar a lo largo de los últimos años. Eso nos permite hacer un análisis comparativo, por ejemplo, entre cursos diferentes, entre los mismos cursos pero diferente año o entre los mismos alumnos que cursaron diferentes años.

4.2 Generación de *Situaciones de Usuario* a partir de *SAVER*

El primer paso para la construcción de los perfiles de usuario, es la generación de las *Situaciones de Usuario* a partir de la base de datos de *SAVER*. En esta sección detallamos cómo se llevó a cabo esa generación.

Las *Situaciones de Usuario* son tuplas con el formato (C, t) donde t es una tarea que el estudiante puede realizar en *SAVER* (como ser realizar una evaluación o leer la explicación de un determinado tema) y C es un conjunto de atributos contextuales de la forma $C = \{a_1, \dots, a_n\}$. Por ejemplo, la situación en la que un alumno lee una explicación teórica sobre probabilidades condicionales del curso de Redes Bayesianas se describiría como: $(CursoBayes, Unidad2, TemaProbCondicional, TipoExplicaciónTeórico, AcciónLee)$. En esta propuesta los atributos contextuales están representados como conceptos de las ontologías descritas en la próxima sección.

En *SAVER*, cada vez que el estudiante realiza una tarea determinada, el sistema envía al servidor un evento que indica qué tarea se ejecutó. Al detectar ese evento, el sistema reacciona ejecutando el procesamiento correspondiente. A su vez, el sistema se encarga de almacenar en una base de datos las acciones de los estudiantes cuando interactúan con las aplicaciones que brinda *SAVER*, codificando el contexto y condiciones que disparan la ejecución de esa tarea. A partir de la información almacenada en dicha base de datos generamos las *Situaciones de Usuario*.

Para generar las *Situaciones de Usuario* procedemos de la siguiente manera. Para cada estudiante registrado en *SAVER*, se busca en la base de datos todas las tareas que ha realizado en el sistema. Llamamos T al conjunto de tareas realizadas por un determinado estudiante. Luego, por cada tarea t_i perteneciente a T , creamos una *Situación de Usuario* formada por t_i y los atributos contextuales que acompañan a esa ejecución en la base de datos. Finalmente, el conjunto de *Situaciones de Usuario* que pueden ser obtenidas luego de este procesamiento forman los datos de entrada de nuestro algoritmo de aprendizaje.

4.3 Dimensiones Contextuales Desarrolladas para SAVER

En esta sección se presentan brevemente las dimensiones contextuales (representadas por ontologías) que utilizamos para evaluar nuestra propuesta en SAVER. Usamos una *Ontología de Tareas* que describe las posibles tareas que un estudiante puede realizar en SAVER y decidimos modularizar el contexto mediante dos dimensiones contextuales: una *Dimensión Educativa* y una *Dimensión Académica*. A continuación, la descripción de cada una de ellas.

- **Ontología de Tareas:** Una *Ontología de Tareas* contiene características particulares de las tareas que el usuario puede ejecutar en la aplicación bajo estudio. Por lo tanto, en el caso de estudio que estamos desarrollando, esta ontología contiene información sobre las tareas que pueden realizar los estudiantes en un curso de SAVER junto con toda la información que describe una tarea en particular. También describe las posibles tareas que el estudiante puede ejecutar en las herramientas de comunicación que están disponibles en SAVER, tal como recibir, enviar o leer e-mails; leer, responder o redactar en el foro y participar del espacio de trabajo colaborativo.
- **Dimensión educativa:** La ontología que representa esta dimensión describe la estructura y semántica del contenido educativo del sistema. A fin de lograr una futura integración entre SAVER y *AdaptWeb*, buscamos unificar los perfiles de estudiante utilizados en ambas propuestas. Para lograrlo, decidimos utilizar como base la ontología que actualmente se está usando en *AdaptWeb* (descrita en [10]) para representar nuestra dimensión educativa. La ontología utiliza el estándar LOM (Learning Objects Metadata) [11] diseñado por la IEEE. Posteriormente, enriquecimos esa ontología con más conceptos y relaciones con el propósito de incorporar más información contextual a nuestro modelo. A fin de incorporar más información contextual sobre los alumnos, se optó por extraer datos a partir del sistema *SIU-Guaraní* que utiliza la Facultad de Ciencias Exactas de la UNICEN. El sistema *SIU-Guaraní* es un sistema de gestión de alumnos que registra y administra todas las actividades académicas de la universidad. Tomando como base la ontología de conocimiento de *AdaptWeb* y a partir de los datos provenientes de SAVER y del *SIU-Guaraní*, se construyó la ontología de educación presentada en la Figura 2. La ontología sigue una propuesta jerárquica similar a la estructura de un libro de texto con capítulos y secciones para estructurar el contenido educativo. Luego, objetos de aprendizaje representando explicaciones de tópicos se relacionan a ejercicios, exámenes y material complementario para dar soporte al aprendizaje.
- **Dimensión académica:** Esta dimensión describe la actividad actual y la historia académica del estudiante. Por actividad actual consideramos los objetivos educativos actuales del estudiante, como ser los cursos que está realizando y su estilo de aprendizaje. Por historia académica entendemos los conocimientos ya adquiridos por el estudiante y los cursos aprobados anteriormente. Además, de cada estudiante consideramos sus objetivos de aprendizaje, conocimiento del dominio, conocimientos previos, estilos de aprendizaje, entre otros. A fin de continuar buscando la integración entre SAVER y *AdaptWeb*, se incorporaron a esta ontología parte de la ontología del estudiante propuesta en *AdaptWeb*.

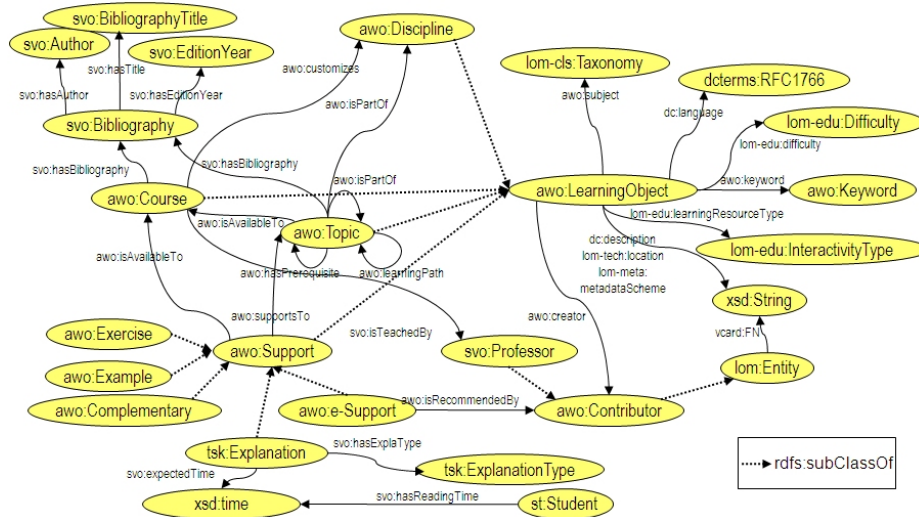


Figura 2. Ontología educativa utilizada en el caso de estudio

5 Resultados Experimentales

En esta sección se presentan los resultados obtenidos a partir de la evaluación experimental. Para realizar las pruebas, fueron implementados dos tipos de perfil de usuario: i) un perfil enriquecido semánticamente construido a partir de la técnica propuesta; y ii) otro sin esa característica construido a partir de reglas de asociación. El objetivo es mostrar las ventajas y desventajas de nuestro trabajo que considera semántica común entre atributos contextuales versus uno que no lo considere.

5.1 Datos Experimentales

Para la evaluación de este experimento se utilizó la información disponible en la base de datos de *SAVER*. En particular, se trabajó con los datos de un grupo de 52 estudiantes que utilizaron el sitio de educación a distancia para realizar el curso “Introducción a Redes de Bayes”. Todos los estudiantes que participaron pertenecen a la carrera de Ingeniería de Sistemas de la UNICEN.

Los estudiantes realizaron distintas tareas con el objetivo final de aprobar el curso web. Estos estudiantes durante el curso podían leer el material educativo disponible, realizar ejercicios, realizar evaluaciones (obligatorias) y autoevaluaciones (opcionales), trabajar colectivamente para realizar trabajos en grupo, compartir archivos a través del espacio compartido de trabajo y comunicarse mediante diferentes herramientas que provee *SAVER* tal como chat, foro o correo electrónico. En un determinado curso, cada unidad está dividida en un conjunto de temas; los que a su vez cuentan con varios ejemplos y ejercicios. Por lo tanto, los resultados obtenidos en los experimentos fueron procesados promediando el comportamiento de los estudiantes en diferentes unidades y temas.

La generación del escenario se desarrolló de la siguiente manera. En *SAVER*, todas las interacciones que realizaban los alumnos en el curso, iban siendo monitoreadas y almacenadas en la base de datos. Entonces, a partir de esa base de datos generamos las *situaciones de usuario* correspondientes (según se describió en la Sección 4.2). En total, se recolectaron 1877 *situaciones de usuario* de 52 estudiantes diferentes. Ese conjunto de situaciones fue dividido aleatoriamente en un sub-conjunto de situaciones de entrenamiento (2/3 de las situaciones originales) y otro de situaciones de prueba (1/3 de las situaciones originales). Algunas variables numéricas y temporales fueron promediadas, como por ejemplo las fechas de inicio y fin de sesión. Cada *situación de usuario* estaba compuesta por la *explicación* que leyó el estudiante y *atributos contextuales* que describen la situación en la que se produjo esa lectura. Luego, buscamos la semántica común a esos atributos para encontrar el contexto relevante para ese estudiante utilizando sólo las situaciones de entrenamiento. Finalmente, validamos el contexto aprendido utilizando las situaciones de prueba. En las situaciones de prueba, se encuentran explicaciones que son relevantes para el usuario (porque las ha leído) pero que no fueron consideradas en el aprendizaje. Por lo tanto, medimos si a partir del contexto aprendido somos capaces de detectar como relevantes las explicaciones que están en las situaciones de prueba.

5.2 Recomendación de Explicaciones Relevantes

En este experimento se comparó la performance de recomendación de explicaciones a estudiantes: a) con y b) sin usar nuestro Perfil de Usuario enriquecido semánticamente. Por lo tanto, se implementó una aplicación JAVA como herramienta de testeo. Esta herramienta recomienda explicaciones relevantes para los estudiantes primero a) usando un Perfil de Usuario basado en reglas de asociación y luego b) usando nuestro Perfil de Usuario enriquecido semánticamente.

El experimento se llevó a cabo mediante dos etapas diferentes: i) en primer lugar, construimos un Perfil de Usuario individual para cada estudiante involucrado en el experimento usando sólo reglas de asociación; y ii) en segundo lugar, construimos otro Perfil de Usuario utilizando el modelo propuesto en [3].

Para generar reglas de asociación, usamos el ampliamente conocido algoritmo Apriori [12] de la herramienta WEKA [13]. Determinamos empíricamente los parámetros de confianza y soporte utilizados para correr los algoritmos: $\text{minconf} = 0.8$, $\text{minsup} = 1/N$, donde N es el número de instancias en el conjunto de datos.

En la segunda etapa de este experimento, vamos a recuperar las explicaciones relevantes para los estudiantes utilizando el perfil de usuario propuesto. Por lo tanto, dos posibles métricas de efectividad son *precision* y *recall* [14]. Estas métricas se definen de la siguiente manera:

$$\text{Precision} = \frac{\text{Número de explicaciones relevantes recuperadas}}{\text{Número de explicaciones recuperadas}}$$

$$\text{Recall} = \frac{\text{Número de explicaciones relevantes recuperadas}}{\text{Número de explicaciones relevantes}}$$

Inicialmente, calculamos *precision* y *recall* para cada estudiante a partir del perfil con reglas de asociación. Posteriormente, recalculamos ambas métricas para cada estudiante pero esta vez a partir de nuestro perfil con ontologías. En particular, para cada estudiante comparamos el número de explicaciones relevantes recuperadas contra a) el número total de explicaciones recuperadas y b) el número total de explicaciones relevantes para el estudiante. Consideramos que una explicación es relevante para el estudiante cuando ha leído esa explicación en *SAVER*. En esta propuesta, en lugar de solicitar al usuario que brinde feedback explícito, inferimos que el estudiante está interesado en una explicación en base a su comportamiento en el sistema.

Con el objetivo de facilitar la comparación del Perfil de Usuario basado en reglas y el Perfil de Usuario propuesto en esta tesis, creamos gráficos de *precision* y *recall* separados. La Figura 3 presenta los resultados experimentales. Concretamente, la Figura 3 (a) muestra los valores de *precision*; mientras que la Figura 3 (b) muestra los valores de *recall* para ambas propuestas. Para hacer los resultados comparables, los valores presentados se obtuvieron promediando precisión y recall para los diferentes conjuntos de datos pertenecientes a los estudiantes.

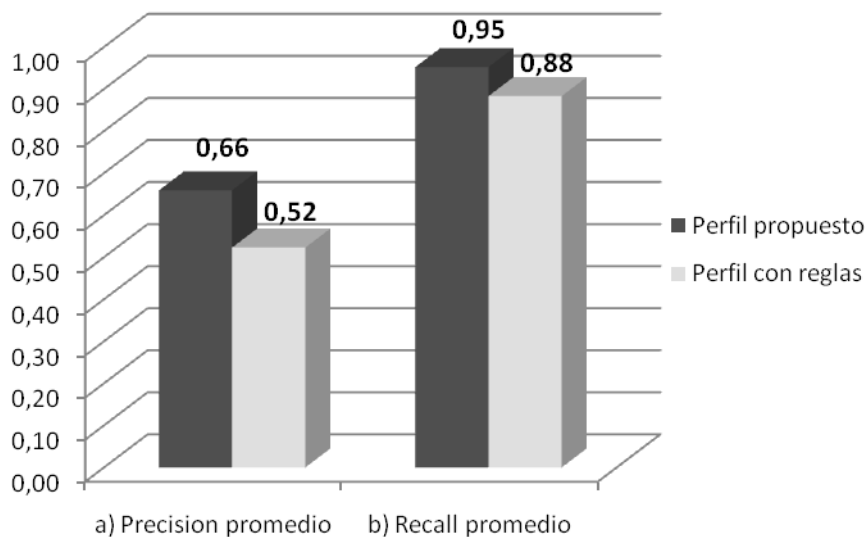


Figura 3. Precisión promedio y recall promedio de ambas propuestas

Los resultados experimentales muestran mejoras cuando se utiliza el Perfil de Usuario propuesto para recomendar explicaciones a los estudiantes. Como se visualiza en la Figura 3 (a), las recomendaciones utilizando nuestro perfil superan a las recomendaciones con reglas de 0,66 a 0,52 en precisión promedio. Por lo tanto, nuestra propuesta tiene un incremento del 14 % en precisión promedio cuando se la compara con la otra propuesta. En promedio, sin usar nuestro Perfil de Usuario, sólo cerca del 50 % de las explicaciones relevantes eran recuperadas.

Además, como se puede ver en la Figura 3 (b), el recall también se mejoró. Las recomendaciones que usan nuestro Perfil de Usuario poseen un recall mayor (0,95) que las recomendaciones con reglas (0,89). Sin embargo, los valores de recall promedio de ambas propuestas están cercanos. La recomendación de explicaciones usando nuestro perfil produjo un incremento promedio en recall del 0,06.

Podemos realizar algunas observaciones a partir de este experimento. En general, los resultados de los experimentos muestran que la recomendación de explicaciones utilizando perfiles de usuario personalizados logra una buena performance tanto en precisión como en recall. Sin embargo, las mejoras obtenidas no fueron tan significativas como las esperadas. Tenemos dos posibles explicaciones para este resultado. En primer lugar, el tamaño reducido de las ontologías usadas en los experimentos no permitió detectar relaciones semánticas útiles entre los atributos. En segundo lugar, el conjunto de datos no fue lo suficientemente grande como para aportar ejemplos representativos del comportamiento de los usuarios.

6 Conclusiones

A la hora de personalizar un sitio de educación a distancia no basta con tener información sobre los hábitos y preferencias del estudiante, también es de suma importancia conocer el contexto en el que se encuentra esa persona. Contar con información contextual brinda la posibilidad de individualizar y mejorar la calidad de la personalización ofrecida al estudiante en cada momento particular.

En este trabajo se aprende cuál es el contexto relevante para el estudiante a partir de la evidencia disponible. Esa evidencia está formada por las acciones que realiza el estudiante en el sitio de educación a distancia y por conocimiento adicional proveniente de ontologías de dominio. Sin embargo, no todas las personas usan el sitio de la misma manera. Consecuentemente, en el proceso de inferir el contexto relevante se consideró también las preferencias y hábitos de cada estudiante en el uso del sitio de educación.

Los resultados experimentales obtenidos en el caso de estudio proveen evidencia de la efectividad de usar una propuesta ontológica para perfiles de usuario en sitios de educación a distancia. Por lo tanto, estamos convencidos que contexto es el eslabón perdido para mejorar los sistemas de educación a distancia actuales con el objetivo de alcanzar personalizaciones más útiles y amigables.

Referencias

1. *Web-Based Learning Support System*. **Fan, Lisa**. s.l. : Springer London, 2010, págs. 81--95.
2. *Personalized e-learning environments: considering students' contexts*. **Eyharabide, Victoria, y otros**. 2009, Proceedings of WCCE 2009, World Conference on Computers in Education Ifip - International Federation for Information Processing.

3. *An Ontology-Driven Conceptual Model of User Profiles*. **Eyharabide, Victoria y Amandi, Analia**. Mar del Plata, Argentina: s.n., 2007. En Proceedings of ASAI07, Simposio Argentino de Inteligencia Artificial, como parte de JAIIO'07.
4. *An adaptive navigation support system for conducting context-aware ubiquitous learning in museums*. **Chiou, Chuang-Kai, y otros**. 2010, Computers and Education, Vols. In Press, Corrected Proof, págs. -.
5. *Personalized Knowledge Acquisition through Interactive Data Analysis in E-learning System*. **Zhao, Zhongying, y otros**. 5, 2010, Journal of Computers, Vol. 5, págs. 709-716.
6. *User Models for Adaptive Hypermedia and Adaptive Educational Systems*. **Brusilovsky, Peter y Millan, Eva**. 2007a, The Adaptive Web, Vol. 4321, págs. 3-53.
7. *A fully personalization strategy of E-learning scenarios*. **Essalmi, Fathi, y otros**. 4, 2010, Computers in Human Behavior, Vol. 26, págs. 581 - 591.
8. *A Heuristic Algorithm for planning personalized learning paths for context-aware ubiquitous learning*. **Hwang, Gwo-Jen, y otros**. 2, 2010, Computers and Education, Vol. 54, págs. 404 - 415.
9. *eTeacher: Providing personalized assistance to e-learning students*. **Schiaffino, Silvia, Garcia, Patricio y Amandi, Analia**. 4, 2008, Computers and Education, Vol. 51, págs. 1744 - 1754.
10. *Adaptive Web-Based Courseware Development Using Metadata Standards and Ontologies*. **Munoz, Lydia Silva y de Oliveira, Jose Palazzo Moreira**. 2004, Advanced Information Systems Engineering, Vol. 3084, págs. 257-279.
11. *Learning Technology Standards Committee of the IEEE. Draft Standard for Learning Object Metadata (LOM)*. **LOM**. 2002, IEEE, Vols. 1484.12.1-2002.
12. *Parallel Mining of Association Rules*. **Agrawal, Rakesh y Shafer, John C**. 6, Piscataway, NJ, USA: IEEE Educational Activities Department, 1996, IEEE Transactions on Knowledge and Data Engineering, Vol. 8, págs. 962--969.
13. *Data Mining: practical machine learning tools and techniques*. **Witten, Ian H. y Frank, Eibe**. 2005.
14. *Methods and techniques for the evaluation of user-adaptive systems*. **Cristina, Gena.** 1, New York, NY, USA: Cambridge University Press, 2005, The Knowledge Engineering Review, Vol. 20, págs. 1--37.