





## RESUMEN DEL CONTENIDO DE TESIS DOCTORAL

1.- Título de la Tesis	
Español/Otro Idioma: Variables de comportamiento para desarrollar un modelo de interacción en los LMSs	Inglés: Behavioral variables for developing an interaction model in LMSs
2.- Autor	
Nombre: Miguel Sánchez Santillán	DNI/Pasaporte/NIE:
Programa de Doctorado: Programa de Doctorado en Ingeniería Informática	
Órgano responsable: Centro Internacional de Postgrado	

### RESUMEN (en español)

En nuestra vida diaria hemos integrado progresivamente el uso de Internet. Esta incorporación también se ha producido en todos los niveles educativos, donde los entornos virtuales de aprendizaje (LMSs) son el medio utilizado, por profesores, estudiantes e instituciones, para el manejo y la distribución de experiencias educativas. Sin embargo, tal y como están diseñados estos sistemas, hacen que los estudiantes tengan dificultades para desplegar sus habilidades metacognitivas, además de provocar una sobrecarga cognitiva debido a una mala organización de los contenidos y de la navegación. Es necesario, por tanto, incluir en las plataformas de aprendizaje un mecanismo que permita la adaptación de estos sistemas a las características, necesidades y contexto del alumno con el objetivo de optimizar el proceso de enseñanza-aprendizaje (E-A).

El objetivo principal de esta tesis doctoral es descubrir variables de comportamiento de los alumnos en los LMSs que puedan ser empleadas en un modelo de interacción y adaptación con el fin de mejorar el proceso E-A. Para alcanzar este objetivo, se ha desarrollado un modelo teórico de interacción y adaptación para LMSs que permita la mejora del proceso E-A y se han obtenido patrones y variables de comportamiento en los LMSs que influyen en los procesos de aprendizaje de los alumnos.

En primer lugar, se describe un modelo de interacción y adaptación LMSs que, utilizando variables centrales en el proceso de aprendizaje, permite aplicar reglas adaptativas a los distintos tipos de contenidos y conocimientos que se han de transmitir o adquirir. A nivel aplicado, el modelo obtenido permite desarrollar cursos adaptados que dan soporte y promueven el aprendizaje y la autorregulación dentro de los entornos de aprendizaje virtuales. Además, se presenta una implementación de un prototipo del modelo en la arquitectura Moodle.

En segundo lugar, se estudiaron los procesos de aprendizaje de los alumnos en LMSs empleando el enfoque de la Minería de Datos Educativa (EDM). Se empleó un conjunto de datos extraído a través de los logs de interacción de los alumnos (N = 140) en una plataforma Moodle. Se agruparon a los alumnos según su interacción mediante clustering y se relacionaron con distintos tipos de rendimiento, en base a variables relacionadas con el esfuerzo, el tiempo de trabajo y la procrastinación. Se descubrieron cuatro patrones de aprendizaje diferentes con distintos niveles de rendimiento. Además, los resultados mostraron que hay variables que tienen mayor relación con el rendimiento de los alumnos y con la idoneidad para configurar los clusters. En base a estos resultados, los clusters se etiquetaron de la siguiente manera: dos grupos orientados a la actividad (enfoque individual o social) y dos grupos no orientados a la actividad (procrastinadores o no procrastinadores). Los resultados obtenidos tienen implicaciones en el diseño de programas de intervención para mejorar tanto los procesos de aprendizaje de los alumnos, como el rendimiento en los LMSs.

Por último, se realizó un estudio, basado en técnicas de EDM, para evaluar la relación del comportamiento procrastinador de los alumnos en un LMS y el rendimiento obtenido. Se emplearon dos conjuntos de datos ( $N_1 = 67$  y  $N_2 = 73$ ) de dos años consecutivos, obtenidos de



los logs de interacción de los alumnos en un curso sobre una plataforma Moodle. Se seleccionaron variables relacionadas con la procrastinación, el tiempo de estudio y el esfuerzo, y el rendimiento obtenido por los alumnos. Posteriormente, se analizó la muestra mediante reglas de asociación con clase (CAR), con un mínimo de 0,80 de precisión, empleando en el consecuente los diferentes niveles de rendimiento (bajo, medio y alto). Se obtuvieron 111 reglas de asociación entre los dos conjuntos de datos, tres de ellas presentes en ambos conjuntos. Los resultados obtenidos, confirman la relación inversa del comportamiento procrastinador y el rendimiento de los alumnos en LMSs, así como el valor predictivo, en cursos sucesivos, de las reglas de asociación basadas en este tipo de variables.

### RESUMEN (en Inglés)

The use of the Internet has been progressively integrated into our daily lives. This has also been true for all levels of education, where virtual learning environments have been the means by which teachers, students and educational institutions managed and distributed educational experiences. However, the present design of these systems cause students disabilities in deploying their meta-cognitive skills, in addition to producing a cognitive overload due to an inadequate content organisation and navigation. Thus, it is necessary to provide learning platforms with a process that allows for the adaptation of these systems to students' characteristics, needs and context in order to enhance the teaching-learning process.

The main objective of this PhD dissertation is to determine and include students' behavioral variables in an interaction-adaptation model for enhancing the teaching-learning process in Learning Management Systems (LMSs). For this purpose, a theoretical model of interaction and adaptation for LMSs was developed. Then, patterns and behavior variables that are related to the students' learning processes were obtained from two different studies.

The first study describes an adaptive model for LMSs that using variables central to the learning process allows for the application of adaptive rules to the different types of contents and knowledge to be transferred and acquired. In practice, the resulting model allows to develop adaptive courses that support and promote learning and self-regulation in virtual learning environments. In addition, a prototype of the model obtained was developed into a Moodle platform.

The second study intends to examine students' asynchronous Learning processes via an Educational Data Mining approach using data extracted from the Moodle logs of students who were grouped according to similar behaviors regarding effort, time spent working, and procrastination. The behaviors were then matched with different levels of achievement. First, the different patterns of students' involvement in the learning process in a Learning Management System were clustered. Second, the different variables selected from the Moodle records were studied to see if they were equally suitable for the configuration of student clusters. Third, the relationships between those patterns to students' final marks were examined. After analyzing the log data gathered from a Moodle 2.0 course in which 140 undergraduate students were enrolled, four different patterns of learning with different final marks were found. Additional results showed that there are variables more related to achievement and more suitable to group the students on the basis of which the different groups were characterized, namely, two Task Oriented Groups (socially or individually focused) and two Non Task Oriented Groups (procrastinators or non-procrastinators). These results have implications in the design of interventions for improving students' learning processes and achievement in LMSs.

Finally, the purpose of the third study is to evaluate the students' behavior on a blended learning program and, particularly, their procrastination behaviors in relation with their performance through Data Mining technics. The sample used in this study was the interaction from two groups of students in a LMS during two consecutive academic years ( $N_1=67$ ;  $N_2=73$ ). Relevant interaction variables were selected for the study, taking also into account students' achievement and analyzing data by means of class association rules. In this sense, the association rules were founded and filtered through two selection criteria: 1, rules must have an



accuracy superior to .8 and 2, they are present in both sub-samples. 49 rules during the 1<sup>st</sup> academic year and 62 rules during the 2<sup>nd</sup> academic year with an accuracy superior to 0.94 were found. The findings of this study highlight the influence of time management in online learning environments, particularly in academic achievement, as there is an association between procrastination variables and students' performance. Additional results showed that procrastinating behavior has a predictive value to the student's performance in LMSs.

SR. DIRECTOR DE DEPARTAMENTO DE INFORMÁTICA \_\_\_\_\_/  
SR. PRESIDENTE DE LA COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO EN \_INGENIERIA  
INFORMÁTICA



**UNIVERSIDAD DE OVIEDO**

**Departamento de Informática**



Universidad de Oviedo  
*Universidá d'Uviéu*  
*University of Oviedo*

**Tesis Doctoral**

**Programa de Doctorado en Ingeniería Informática**

Variables de comportamiento para desarrollar un  
modelo de interacción en los LMSs

Autor: Miguel Sánchez Santillán

Directores

Dra. María del Puerto Paule Ruiz

Dra. Rebeca Cerezo Menéndez

Oviedo, 2017



# Agradecimientos

Esta tesis doctoral ha sido parcialmente financiada por el Ministerio de Ciencia e Innovación dentro del Programa Nacional para la Investigación, Desarrollo y la Innovación: proyectos TIN2011-25978 y EDU2014-57571-P. También se han recibido fondos de la Unión Europea, a través de Fondo Europeo de Desarrollo Regional (FEDER); y del Principado de Asturias, a través del Plan de Ciencia, Tecnología e Innovación (PCTI): proyectos GRUPIN14-100 y GRUPIN14-053.

En primer lugar, quiero dar las gracias a mis dos directoras, la Dra. M<sup>a</sup> del Puerto y la Dra. Rebeca Cerezo. Me considero un doctorando afortunado por partida doble, esta tesis doctoral hubiera sido imposible de no ser por su implicación y determinación. Mil y una veces: gracias.

A mis compañeros tanto del grupo PULSO de la facultad de Informática, como a los compañeros del grupo ADIR de la facultad de Psicología.

A mis amigos, por entender mi desorden y estar siempre ahí.

A mis padres por enseñarme el valor del tiempo, a tomarme las cosas con humor. Por apoyarme. Por todo.

A mi primo Tris, por enseñarme a cacharrear desde pequeño con los ordenadores, motivarme con la programación, por su cariño y por su paciencia. Esta tesis está dedicada a él.

*Ni sí, ni no, sino todo lo contrario, 2017.*



# Resumen

En nuestra vida diaria hemos integrado progresivamente el uso de Internet. Esta incorporación también se ha producido en todos los niveles educativos, donde los entornos virtuales de aprendizaje son el medio utilizado, por profesores, estudiantes e instituciones, para el manejo y la distribución de experiencias educativas. Sin embargo, tal y como están diseñados estos sistemas, hacen que los estudiantes tengan dificultades para desplegar sus habilidades metacognitivas, además de provocar una sobrecarga cognitiva debido a una mala organización de los contenidos y de la navegación. Es necesario, por tanto, incluir en las plataformas de aprendizaje un mecanismo que permita la adaptación de estos sistemas a las características, necesidades y contexto del alumno con el objetivo de optimizar el proceso de enseñanza-aprendizaje (E-A).

El objetivo principal de esta tesis doctoral es descubrir variables de comportamiento de los alumnos en las plataformas de aprendizaje (LMSs) que puedan ser empleadas en un modelo de interacción y adaptación con el fin de mejorar el proceso E-A. Para alcanzar este objetivo, se ha desarrollado un modelo teórico de interacción y adaptación para LMSs que soporte este tipo de variables y permita la mejora del proceso E-A. Posteriormente, se han obtenido patrones y variables de comportamiento que influyen en los procesos de aprendizaje basándose en la interacción de los alumnos en los LMSs.

En primer lugar, se describe un modelo de interacción y adaptación LMSs que, utilizando variables centrales en el proceso de aprendizaje, permite aplicar reglas adaptativas a los distintos tipos de contenidos y conocimientos que se han de transmitir o adquirir. A nivel aplicado, el modelo obtenido permite desarrollar cursos adaptados que dan soporte y promueven el aprendizaje y la autorregulación dentro de los entornos de aprendizaje virtuales. Además, se presenta una implementación de un prototipo del modelo en la arquitectura Moodle.

En segundo lugar, se estudiaron qué variables influyen en los procesos de aprendizaje de los alumnos en LMSs empleando el enfoque de la Minería de Datos Educativa (EDM). Se empleó un conjunto de datos extraído a través de los logs de interacción de los alumnos

( $N = 140$ ) en una plataforma Moodle. Se agruparon a los alumnos según su interacción mediante clustering y se relacionaron con distintos tipos de rendimiento, en base a variables relacionadas con el esfuerzo, el tiempo de trabajo y la procrastinación. Se descubrieron cuatro patrones de aprendizaje diferentes con distintos niveles de rendimiento. Además, los resultados mostraron que hay variables que tienen mayor relación con el rendimiento de los alumnos y con la idoneidad para configurar los clusters. En base a estos resultados, los clusters se etiquetaron de la siguiente manera: dos grupos orientados a la actividad (enfoque individual o social) y dos grupos no orientados a la actividad (procrastinadores o no procrastinadores). Los resultados obtenidos tienen implicaciones en el diseño de programas de intervención para mejorar tanto los procesos de aprendizaje de los alumnos, como el rendimiento en los LMSs.

Por último, se realizó un estudio, basado en técnicas de EDM, para evaluar la relación del comportamiento procrastinador de los alumnos en un LMS y el rendimiento obtenido. Se emplearon dos conjuntos de datos ( $N_1 = 67$  y  $N_2 = 73$ ) de dos años consecutivos, obtenidos de los logs de interacción de los alumnos en un curso sobre una plataforma Moodle. Se seleccionaron variables relacionadas con la procrastinación, el tiempo de estudio y el esfuerzo, y el rendimiento obtenido por los alumnos. Posteriormente, se analizó la muestra mediante reglas de asociación con clase (CAR), con un mínimo de 0,80 de precisión, empleando en el consecuente los diferentes niveles de rendimiento (bajo, medio y alto). Se obtuvieron 111 reglas de asociación entre los dos conjuntos de datos, tres de ellas presentes en ambos conjuntos. Los resultados obtenidos, confirman la relación inversa del comportamiento procrastinador y el rendimiento de los alumnos en LMSs, así como el valor predictivo, en cursos sucesivos, de las reglas de asociación basadas en este tipo de variables.

## **Palabras clave**

e-Learning, Plataformas de aprendizaje, interacción, minería de datos educacional, variables educacionales

# Abstract

The use of the Internet has been progressively integrated into our daily lives. This has also been true for all levels of education, where virtual learning environments have been the means by which teachers, students and educational institutions managed and distributed educational experiences. However, the present design of these systems cause students disabilities in deploying their meta-cognitive skills, in addition to producing a cognitive overload due to an inadequate content organisation and navigation. Thus, it is necessary to provide learning platforms with a process that allows for the adaptation of these systems to students' characteristics, needs and context in order to enhance the teaching-learning process.

The main objective of this PhD dissertation is to determine and include students' behavioral variables in an interaction-adaptation model for enhancing the teaching-learning process in Learning Management Systems (LMSs). For this purpose, a theoretical model of interaction and adaptation for LMSs was developed. Then, patterns and behavior variables that are related to the students' learning processes were obtained from two different studies.

The first study describes an adaptive model for LMSs that using variables central to the learning process allows for the application of adaptive rules to the different types of contents and knowledge to be transferred and acquired. In practice, the resulting model allows to develop adaptive courses that support and promote learning and self-regulation in virtual learning environments. In addition, a prototype of the model obtained was developed into a Moodle platform.

The second study intends to examine students' asynchronous Learning processes via an Educational Data Mining approach using data extracted from the Moodle logs of students who were grouped according to similar behaviors regarding effort, time spent working, and procrastination. The behaviors were then matched with different levels of achievement. First, the different patterns of students' involvement in the learning process in a Learning Management System were clustered. Second, the different variables selected from the Moodle records were studied to see if they were equally suitable for the

configuration of student clusters. Third, the relationships between those patterns to students' final marks were examined. After analyzing the log data gathered from a Moodle 2.0 course in which 140 undergraduate students were enrolled, four different patterns of learning with different final marks were found. Additional results showed that there are variables more related to achievement and more suitable to group the students on the basis of which the different groups were characterized, namely, two Task Oriented Groups (socially or individually focused) and two Non Task Oriented Groups (procrastinators or non-procrastinators). These results have implications in the design of interventions for improving students' learning processes and achievement in LMSs.

Finally, the purpose of the third study is to evaluate the students' behavior on a blended learning program and, particularly, their procrastination behaviors in relation with their performance through Data Mining technics. The sample used in this study was the interaction from two groups of students in a LMS during two consecutive academic years ( $N_1=67$ ;  $N_2=73$ ). Relevant interaction variables were selected for the study, taking also into account students' achievement and analyzing data by means of class association rules. In this sense, the association rules were founded and filtered through two selection criteria: 1, rules must have an accuracy superior to .8 and 2, they are present in both sub-samples. 49 rules during the 1<sup>st</sup> academic year and 62 rules during the 2<sup>nd</sup> academic year with an accuracy superior to 0.94 were found. The findings of this study highlight the influence of time management in online learning environments, particularly in academic achievement, as there is an association between procrastination variables and students' performance. Additional results showed that procrastinating behavior has a predictive value to the student's performance in LMSs.

## **Keywords**

e-Learning, learning management systems, interaction, educational data mining,  
behaviorial variables

# Tabla de contenidos

<b>Tabla de contenidos</b> .....	ix
<b>Índice de figuras</b> .....	xiii
<b>1 Introducción</b> .....	1
1.1 Motivación.....	1
1.2 Contribución .....	3
1.3 Estructura del documento .....	4
<b>2 Trabajo relacionado</b> .....	5
2.1 Modelos de adaptación .....	5
2.2 Variables de interacción y rendimiento en LMSs .....	8
2.3 Minería de Datos y la interacción en los LMSs .....	10
<b>3 Modelo de adaptación dinámica en LMSs</b> .....	13
3.1 La interacción de los alumnos en los LMSs .....	13
3.2 Los agentes del aprendizaje vía LMS .....	15
3.3 Naturaleza de las variables de adaptación .....	16
3.4 Las cuatro capas del modelo.....	17
3.4.1 Capa de instrumentos de evaluación.....	18
3.4.2 Capa de variables contextuales .....	18
3.4.3 Capa de procesos de adaptación.....	19
3.4.4 Capa de feedback .....	19
3.4.5 Interacción entre los agentes y las capas del modelo .....	20
3.5 Prototipo en la arquitectura Moodle .....	21
3.5.1 Módulo AdaptiveTest .....	22
3.5.2 Módulo AdaptiveControl.....	23

3.6	Supuesto teórico: Variables motivacionales .....	26
3.6.1	Instrumentos y variables .....	27
3.6.2	Proceso de adaptación.....	28
3.6.3	Adaptación del feedback .....	30
3.7	Discusión .....	31
<b>4</b>	<b>Patrones de comportamiento en LMSs .....</b>	<b>33</b>
4.1	Introducción .....	33
4.2	Objetivos del estudio .....	35
4.3	Metodología.....	36
4.3.1	Participantes y procedimiento .....	36
4.3.2	El proceso de extracción de variables .....	37
4.3.3	Análisis de datos .....	40
4.4	Resultados.....	42
4.4.1	Estadísticos descriptivos .....	42
4.5	Discusión .....	47
<b>5</b>	<b>Variables de procrastinación en LMSs .....</b>	<b>53</b>
5.1	Introducción.....	53
5.2	Objetivos del estudio .....	55
5.3	Metodología.....	56
5.3.1	Participantes y procedimiento .....	56
5.3.2	El proceso de extracción de variables .....	57
5.3.3	Análisis de datos .....	60
5.4	Resultados.....	61
5.4.1	Presencia de las variables en las reglas obtenidas.....	61
5.5	Discusión .....	65
<b>6</b>	<b>Conclusiones .....</b>	<b>67</b>
6.1	Trabajo futuro .....	70

<b>A Diagramas del prototipo implementado</b> .....	73
A.1 Diagrama de paquetes .....	73
A.2 Diagrama de clases del Modelo de usuario .....	74
A.3 Diagrama de clases del módulo AdaptiveControl.....	74
A.4 Diagrama de clases del módulo AdaptiveTest .....	75
A.5 Diagrama de actividad del proceso de adaptación .....	76
<b>B Items del MSLQ del supuesto teórico</b> .....	77
B.1 Items relativos a la autoeficacia macro .....	77
B.2 Items relativos a la orientación a metas intrínsecas .....	78
B.3 Items relativos a la orientación a metas extrínsecas.....	79
<b>C Acciones registradas en logs de Moodle</b> .....	81
<b>D Publicaciones</b> .....	83
<b>Referencias</b> .....	85



# Índice de figuras

Figura 1. Arquitectura AHA! 3.0.....	6
Figura 2. PEAL en combinación con LAG .....	7
Figura 3. Variable del modelo del usuario en GUMF .....	8
Figura 4. Agentes implicados en el modelo y sus acciones.....	16
Figura 5. Relación entre capas según la secuencia y los datos que comparten .....	17
Figura 6. Interacción de los agentes implicados con la arquitectura del modelo .....	20
Figura 7. Diagrama de clases de la arquitectura del prototipo. ....	22
Figura 8. Interfaz del módulo AdaptiveTest para añadir variables .....	23
Figura 9. Ejemplo de reglas de visibilidad total y parcial .....	24
Figura 10. Editor de precondiciones en las reglas de completitud .....	25
Figura 11. Acciones disponibles en las reglas de completitud .....	26
Tabla 1. Instrumentos de medida, variables de adaptación y sus valores .....	27
Figura 12. Representación teórica del proceso de adaptación y del de feedback. ....	29
Figura 13. Estructura de los logs en la plataforma Moodle. ....	38
Tabla 2. Categorización y descripción de las variables seleccionadas. ....	39
Tabla 3. Proceso de extracción de las variables empleadas. ....	40
Tabla 4. Correlación de Pearson, media, desviación típica, mínimo y máximo .....	42
Tabla 5. Media y desviación típica de los centroides de las variables en los clusters ...	44
Figura 14. Clusters con la media y desviación típica del rendimiento. ....	45
Tabla 6. Categorización y descripción de las variables seleccionadas. ....	58
Tabla 7. Proceso de extracción de las variables empleadas. ....	59
Tabla 8. Método y valores de la discretización de las variables.....	60
Figura 15. Aparición de las variables en los conjuntos de datos .....	62

Tabla 9. Aparición de las variables en las reglas de asociación .....	62
Figura 16. Reglas de asociación presentes en los dos conjuntos de datos .....	64
Figura 17. Diagrama de paquetes del prototipo implementado .....	73
Figura 18. Diagrama de clases del modelo de usuario .....	74
Figura 19. Diagrama de clases del módulo AdaptiveControl.....	74
Figura 20. Diagrama de clases del módulo AdaptiveTest .....	75
Figura 21. Diagrama de actividad del proceso de adaptación .....	76
Tabla 10. Acciones registradas en los logs de Moodle .....	81

# Capítulo 1

## Introducción

### 1.1 Motivación

El origen de los sistemas hipermedia educativos está ligado a la aparición de los primeros tutores inteligentes (Polson y Richardson, 1988). Estos tutores estaban orientados al alumno y se basaban en combinar los materiales a estudiar con resultados de cuestionarios para establecer una secuenciación adaptativa del curso.

Gracias a la evolución de la tecnología, comenzaron a desarrollarse los denominados Sistemas Hipermedia Adaptativos Educativos (SHAE). El objetivo principal de estos sistemas es adaptar la forma en la que se presenta el conocimiento al alumno, según determinadas características, como el conocimiento que posee sobre una temática o los estilos de aprendizaje (Stash, Cristea, y De Bra, 2004).

Una de las aportaciones de los sistemas hipermedia adaptativos en el e-Learning es la aplicación del modelo de adaptación (Ruiz, Díaz, Soler, y Pérez, 2008). A través de la hipermedia adaptativa se organiza, tanto la visualización del contenido, como el orden en el que se presenta en los sistemas e-Learning, basándose en las técnicas y métodos propuestos por Peter Brusilovsky (Brusilovsky, 1996). La adaptación se realiza en función del valor de diferentes parámetros, cuyo conjunto se denomina modelo de usuario.

A pesar de las posibilidades adaptativas de los SHAEs, en la actualidad se emplean plataformas de aprendizaje o LMSs (Learning Management Systems) que, actualmente, presentan mecanismos de adaptación limitados (Akbulut y Cardak, 2012; David Hauger y Köck, 2008). El uso de LMSs se debe a que incluyen un conjunto de herramientas integradas para: la creación y mantenimiento de cursos, inscripción de alumnos y tareas

de administración, entre otras (Dagger, O'Connor, Lawless, Walsh, y Wade, 2007), es decir, son sistemas más completos.

El e-Learning, b-Learning y el uso de los LMSs es una realidad que marca el proceso de enseñanza-aprendizaje (E-A), especialmente en la educación superior. El uso de estas plataformas se ha generalizado con el objetivo de ofrecer soporte a las asignaturas u ofertar cursos exclusivamente online. Sin embargo, el aprendizaje a través de un LMS, requiere un plus por parte de los alumnos para decidir qué, cómo y cuánto van aprender, como gestionar el esfuerzo, etcétera. (Roger Azevedo, Cromley, Winters, Moos, y Greene, 2005). Todas estas dudas pueden quedar resueltas en una clase magistral, en una sesión práctica pero ¿qué ocurre si es una asignatura impartida exclusivamente a través de la plataforma? En este sentido, los datos de los que se dispone respecto al aprendizaje en educación superior indican que la mayoría de los estudiantes no están adecuadamente preparados para lo que se requiere de ellos en este contexto (Roger Azevedo y Feyzi-Behnagh, 2011). Por ello, tratar de paliar esas dificultades añadidas parece una cuestión importante y urgente, dada la rapidez con la que el uso de estos entornos se generaliza.

Además, explorar cómo los diferentes patrones de comportamiento de los alumnos en los LMSs están relacionados con el rendimiento final, podría ser muy útil en el diseño de entornos virtuales de aprendizaje adaptados (Bra y Calvi, 1998; Brusilovsky, 1996). Recientemente, ha aparecido una nueva tendencia a la hora de diseñar este tipo de entornos, basándose en los datos de la interacción realizada por los alumnos con el sistema a bajo nivel de granularidad (Romero, Ventura, Zafra, y Bra, 2009; Romero, Ventura, y García, 2008). El objetivo principal de esta nueva tendencia es refinar al máximo el andamiaje que el sistema proporciona a cada alumno. Tal y como evidenciaron previamente Dabbagh y Kitsantas (2005, 2013), andamiar la adquisición de los procesos SRL (Self-Regulated Learning o Aprendizaje Autorregulado) del alumno es especialmente importante en los cursos online porque, frecuentemente, se les pide que completen tareas de aprendizaje con poco o nulo soporte, teniendo que ser alumnos altamente autoregulados.

El objetivo principal de esta tesis doctoral es descubrir variables de comportamiento de los alumnos en los LMSs que puedan ser empleadas en un modelo de interacción y adaptación con el fin de mejorar el proceso E-A. Para alcanzar este objetivo, se ha desarrollado un modelo teórico de interacción y adaptación para LMSs que soporte este

tipo de variables y permita la mejora del proceso E-A. Posteriormente, se han obtenido patrones y variables de comportamiento que influyen en los procesos de aprendizaje basándose en la interacción de los alumnos en los LMSs.

## 1.2 Contribución

A continuación, se presentan las contribuciones más representativas de esta tesis doctoral:

1. Un modelo de interacción y adaptación teórico basado en un modelo de usuario flexible, en el que, los valores de las variables, pueden almacenarse de forma independiente según el ámbito en el que se apliquen (curso, tema, elemento). Este modelo persigue la mejora del proceso enseñanza-aprendizaje, mediante la implicación de los tres agentes fundamentales: el alumno, el docente, y el LMS; empleando un sistema de 4 capas: instrumentos de evaluación, variables contextuales, procesos de adaptación, y feedback.
2. Una propuesta de implementación del modelo anterior sobre un LMS sin necesidad de modificar el código base del sistema. A través de dos módulos, se implementa el modelo de interacción-adaptación, siendo completamente funcional y añadiendo procesos de adaptación al LMS de forma transparente.
3. Un conjunto de variables de esfuerzo/tiempo de trabajo y procrastinación, obtenidas de la interacción de los alumnos con un LMS que influyen en el rendimiento final obtenido. Se presentan qué variables influyen en mayor, o menor medida, con el rendimiento de los alumnos. Concretamente, las variables relacionadas con el tiempo de trabajo en la actividad y el tiempo que tardan en entregar la actividad, se relacionan de forma directa e inversa, respectivamente, con el rendimiento.
4. Obtención de patrones de comportamiento basados en la interacción de los alumnos con un LMS relacionados con el rendimiento final obtenido. Empleando clustering se obtienen 4 perfiles de estudiantes tipo: grupo no orientado a la actividad (no procrastinadores), grupo no orientado a la actividad (procrastinadores), grupo orientado a la actividad (enfoque individual) y grupo orientado a la actividad (enfoque social).
5. Evaluación del valor predictivo, y consistente en el tiempo, de las variables de procrastinación en cuanto al rendimiento de los alumnos en los LMSs. A través de

algoritmos basados en reglas de asociación con clase, y su filtrado en diferentes muestras y años académicos, se confirma la relación inversa de la procrastinación y el rendimiento de los alumnos.

### **1.3 Estructura del documento**

La presente tesis doctoral está estructurada de la siguiente manera. En el siguiente capítulo se estudian los trabajos relacionados, describiendo: los modelos de adaptación más destacados; estudios relacionados con variables obtenidas de la interacción de los alumnos en LMSs y su influencia en el rendimiento, y estudios relacionados con la interacción de los alumnos en LMSs y el uso de técnicas de Minería de Datos. En el capítulo 3 se presenta un modelo teórico de interacción y adaptación para LMSs y la implementación de un prototipo en una arquitectura Moodle. En el capítulo 4 se generan, mediante clustering, y se analizan los patrones de comportamiento de los alumnos en un LMS, relacionándolos con el rendimiento final. En el capítulo 5 se analiza cómo las variables de procrastinación obtenidas mediante reglas de asociación, pueden ayudar a predecir el rendimiento de los alumnos en años consecutivos. En el capítulo 6, se presentan las conclusiones y el trabajo futuro.

El apéndice A contiene diagramas más detallados de la implementación del modelo en la arquitectura Moodle. El apéndice B contiene los ítems relacionados con el supuesto teórico de adaptación. El apéndice C contiene todas las acciones que generan los diferentes módulos base de Moodle. El apéndice D contiene todas las publicaciones derivadas de esta tesis doctoral.

# Capítulo 2

## Trabajo relacionado

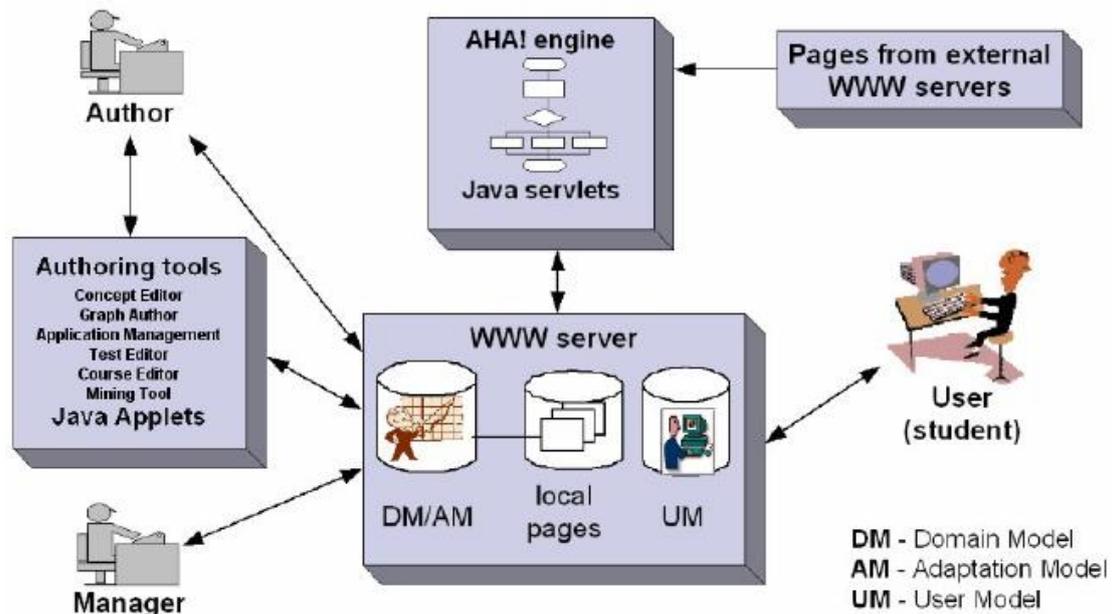
En este capítulo se describen las investigaciones existentes relacionadas con la presente tesis doctoral. En la primera sección, se describen y analizan aquellos modelos de adaptación, relacionados con el aprendizaje online, presentados en orden cronológico de aparición. En la segunda sección, se estudian las investigaciones previas relacionadas con las variables obtenidas a través de interacción de los alumnos en los LMSs y su influencia en el rendimiento. Por último, se estudian las investigaciones relacionadas con el análisis de la interacción de los alumnos en LMSs mediante técnicas de Minería de Datos.

### 2.1 Modelos de adaptación

La investigación sobre hipermedia educacional adaptativa surge en la década de los 90, con la idea de crear sistemas educacionales adaptados a los estudiantes. Las primeras propuestas de investigación aparecen entre 1990 y 1996, dando lugar a dos líneas: los Tutores inteligentes (ITS), y los Sistemas hipermedia adaptativos educacionales (AEHS) que incluyen modelos de adaptación basados en las técnicas y métodos de la Hipermedia Adaptativa (Brusilovsky, 1996, 2001), con el fin de adaptar el proceso E-A a las características del alumno. En este apartado, se estudia la evolución de estos modelos de adaptación hasta su integración con los actuales LMSs.

*AHA!* (Bra y Calvi, 1998; De Bra, Stash, Smits, Romero, y Ventura, 2007) o también conocido como “Adaptive Hypermedia For All” o “Adaptive Hypermedia Architecture”, es una arquitectura para crear aplicaciones web adaptativas, cuyo motor de adaptación está escrito en Java. La arquitectura está planeada para la intervención de cuatro agentes (ver figura 1): el autor de contenidos y el gestor, que crean contenidos, los relacionan con conceptos y éstos, con las reglas de adaptación; el alumno, que proporciona información personal e interactúa con la arquitectura; y el motor de adaptación, que proporciona el

aprendizaje adaptado al alumno y proporciona feedback a los cuatro agentes. Las reglas de adaptación se basan en reglas condicionales incrustadas en el contenido que afectan tanto, a la presentación del contenido, como a la navegación. Esta circunstancia, permite vincular páginas externas en otros servidores, pero dificulta la reutilización del contenido. Por otra parte, las variables que modelan al usuario, son de tipo entero, cuyo valor debe estar definido en el intervalo [0-100], además son globales, afectando su valor a todas las reglas de la arquitectura.



**Figura 1.** Arquitectura AHA! 3.0 (De Bra et al., 2007)

*My Online Teacher* (MOT) se basa un conjunto de herramientas para la creación y distribución de aprendizaje adaptativo online (Foss y Cristea, 2010). Se basa en los principios de la separación de aspectos, a través del framework LAOS (A. I. Cristea y De Mooij, 2003), separando el proceso de adaptación de contenidos, de la distribución de los mismos. El modelo de adaptación se basa en el lenguaje de adaptación LAG y el editor visual PEAL (Cristea, Smits, Bevan, y Hendrix, 2009). El primero, es un lenguaje de adaptación basado en la reutilización y en posibilitar la creación reglas de adaptación de alto nivel (figura 2), mientras que el segundo es el editor visual de reglas. Además, contempla la interacción de cuatro agentes: el encargado de implementar la adaptación; el docente que implementa los contenidos mediante mapas conceptuales basados en CAF (Common Adaptation Format); y el alumno que recibe el aprendizaje adaptado. Los contenidos generados por MOT, son reutilizables en los sistemas que implementen LAG y CAF, un claro ejemplo es la demostración con AHA! (Cristea, Smits, y de Bra, 2005).

Sin embargo, una vez generado un curso adaptativo, si se desean añadir nuevas variables al modelo de usuario es necesario recompilar todo el proceso.

```

1 //Shows nodes after specific other nodes have been visited
2 //Based on labels
3 //Nodes with weight 1 are source nodes - cause another to be visible
4 //Nodes with weight 2 are target nodes
5 //If they share the same label (arbitrary), viewing source node will
6 show target node
7 //e.g. Show parent once child has been viewed
8 //VARS
9 //UM.GM.curren
10
11 initialization (
12   while true (
13     PM.GM.Concept.show=true
14   )
15
16   while true (
17     if GM.Concept.weight==2 then (
18       PM
19     )
20   )
21 )

```

Found: ): Expect

myfragment  
RollOutnit  
RollOutImplement  
testing  
temp1262636227  
AccessCount  
ShowAll

Insert Code

**Figura 2.** PEAL en combinación con LAG (Cristea et al., 2009)

El proyecto *GRAPPLE* (Generic Responsive Adaptive Personalized Learning Environment) tiene como objetivo fundamental proporcionar una mejora del aprendizaje a largo plazo, adaptándose a diferentes características del alumno (De Bra et al., 2013), tales como: conocimientos previos, metas de aprendizaje, contexto personal y social, preferencias personales y las competencias. La arquitectura está definida por: un LMS para gestionar el proceso de aprendizaje; un motor de adaptación extensible desarrollado en Java que puede ser integrado en distintos LMSs; un framework para gestionar el modelo de usuario GUMF (Grapple User Modeling Framework) (Abel et al., 2009) en cada uno de los LMSs y en cada instancia del motor de adaptación; un sistema de autenticación centralizado; y un framework para la comunicación entre componentes. El framework GUMF se basa en la interoperabilidad entre diferentes aplicaciones, almacena el modelo del usuario en sentencias RDF (ejemplo de cómo se almacena la sentencia “Peter is interested in Darmstadt” en la figura 3) y permite a los LMSs clientes realizar consultas sobre el modelo de usuario en SPARQL y SeRQL. *GRAPPLE* es un proyecto grande, completo y, a su vez, complejo.

```
<gc:Statement rdf:about="&ds10;6357701291243375806816">
  <gc:subject rdf:resource="&guser;peter"/>
  <gc:predicate rdf:resource="&foaf;interest"/>
  <gc:object rdf:resource="&dbpedia;Darmstadt"/>
  <gc:level rdf:datatype="&xsd;double">0.7</gc:level>
  <gc:origin>[peter(Interest: Darmstadt, 0.7)]</gc:origin>
  <gc:created rdf:datatype="&xsd;dateTime">
    2009-05-27T00:10:06.817+02:00</gc:created>
  <gc:creator rdf:resource="&gclient;10"/>
</gc:Statement>
```

**Figura 3.** Variable del modelo del usuario en GUMF

Los modelos estudiados presentan procesos de adaptación basados en variables ya predefinidas (estilos de aprendizaje, adquisición de conocimientos, etc). A continuación, se estudiarán los trabajos previos existentes relacionados con la obtención de nuevas variables que podrían formar parte de los procesos de adaptación

## 2.2 Variables de interacción y rendimiento en LMSs

En las últimas décadas, un gran número de estudios han intentado modelar el comportamiento de los alumnos en LMSs con diferentes objetivos, desde identificar estilos de aprendizaje (Graf y Liu, 2009; Özpolat y Akar, 2009), hasta para predecir la motivación de los alumnos (Dawson, Macfadyen, y Lockyer, 2009; Munoz-Organero, Munoz-Merino, y Kloos, 2010).

Hung and Zhang (2008) descubrieron patrones de comportamiento de los alumnos en LMSs empleando seis variables relacionadas con el esfuerzo del alumno: número de sesiones, frecuencia de acceso a materiales del curso, número de mensajes leídos y escritos, número de discusiones creadas, y el rendimiento final; con el fin de describir y clasificar a los alumnos según sus características. Sin embargo, tal y como apuntan los autores, el uso de técnicas de clustering en este estudio es más descriptivo que predictivo. En un hipotético entorno virtual de aprendizaje adaptado, el rendimiento final de los estudiantes no estaría disponible hasta que finalizase el proceso de aprendizaje. Por tanto, estos resultados podrían ayudar al docente a entender mejor las características del proceso de aprendizaje de sus alumnos, pero no a identificar a los diferentes perfiles, como los alumnos que están en riesgo de abandono.

El tiempo de estudio tradicionalmente, ha sido una variable muy controvertida, a la par que significativa, tanto en el aprendizaje presencial, como a distancia. La relación del

tiempo de estudio con el rendimiento se suele asociar más a la calidad que a la cantidad (Biggs, 1979; Biggs y Biggs, 2004; Dickinson y O'Connell, 1990). Sin embargo, Macfadyen y Dawson (2010), observaron que el tiempo de conexión, el tiempo dedicado a la actividad, y el número de mensajes escritos en el foro, son variables claves para explicar el rendimiento final de los estudiantes. A su vez, el tiempo de conexión y la frecuencia de inicio de sesión se ha utilizado para analizar la relación entre la participación en el LMS y el rendimiento final obtenido en la asignatura (Kupczynski, Gibson, Ice, Richardson, y Chaloo, 2011). Los autores concluyen que los resultados obtenidos necesitan un análisis más profundo, ya que indican que ni el tiempo de conexión en el LMS, ni la cantidad de tiempo por sesión, sirven como indicadores significativos del rendimiento del alumno.

Profundizando más, Murray, Pérez, Geist y Hedrick (2012) han observado que los recursos con los que un alumno interactúa, podrían contribuir a que su aprendizaje sea más fácil y progrese más rápido. En el estudio, se analizan variables relacionadas con el esfuerzo, como por ejemplo: tiempo dedicado a las actividades, resultados, autoinformes, y foros de discusión; con el objetivo de identificar estilos de aprendizaje.

Lust, Elen, y Clarebout (Lust, Elen, y Clarebout, 2013a), observaron cómo los alumnos se diferencian en el uso de herramientas en cada fase del aprendizaje dentro de un LMS. El estudio emplea clustering con variables de interacción, como por ejemplo: tiempo dedicado a la teoría, tiempo dedicado a visitar enlaces, tiempo dedicado a leer feedback, tiempo dedicado a las actividades, mensajes leídos y escritos en los foros. Estos resultados son muy útiles en términos de adaptación, sin embargo, están lejos de predecir el rendimiento del alumno, lo que contribuiría a identificar a los alumnos en riesgo y aplicar sobre ellos determinados procesos de adaptación o recomendación.

Recientemente, Ki, Park, Song, y Jo (J. H. Kim, Park, Song, y Jo, 2014) han encontrado patrones de comportamiento basados en la interacción de los alumnos que predicen su rendimiento académico. En este caso, se comparan dos cursos, tipo A, donde la mayoría de la interacción se realizaba en foros, y tipo B, que además incorporaba actividades y recursos online.

En el estudio realizado por Zacharis (2015), se analiza la interacción de los alumnos en el LMS con el fin de predecir el rendimiento de los alumnos en un curso b-Learning. Los resultados muestran que de 29 variables, cuatro de ellas: interacción en los foros,

creación de contenidos, esfuerzo en cuestionarios y número de recursos consultados, explican el 52% de la varianza en el rendimiento de los estudiantes.

Por otra parte, el impacto negativo de la procrastinación en el rendimiento académico como un fallo de la autorregulación ha recibido un considerable soporte empírico (Howell y Watson, 2007). Además, Tuckman (2005) confirmó no sólo que los procrastinadores en plataformas e-Learning tienden a rendir peor que los no procrastinadores, si no que también confirmó que la relación entre la procrastinación y el rendimiento en estas plataformas, es mucho más fuerte que en el aprendizaje tradicional. En este sentido, Michinov et al. (2011) hallaron evidencias de que los alumnos altamente procrastinadores en los LMSs obtienen menor rendimiento que los alumnos no procrastinadores. Posteriormente, You (2015) estudió el efecto de la procrastinación académica en el rendimiento de un curso online, descubriendo que el retraso en las entregas, o la falta de ellas, se relaciona de forma negativa con el rendimiento. Además, Goda, Yameda, Kato, Matsuda, Saito y Miyagawa (2015) encontraron siete patrones de comportamiento de los alumnos en plataformas de aprendizaje, destacando el buen rendimiento de los alumnos con hábitos de aprendizaje frente a los alumnos con un perfil procrastinador.

## **2.3 Minería de Datos y la interacción en los LMSs**

La Minería de Datos Educativa se basa en el desarrollo y la aplicación de algoritmos de computación para detectar patrones en grandes colecciones de datos educacionales, que de otra forma, serían difíciles, o incluso, imposibles de analizar (Romero, Ventura, Vasilyeva, y Pechenizkiy, 2010). Además, esta disciplina también se aplica para examinar la interacción de los alumnos almacenada en los registros de los LMSs (Romero et al., 2008). A continuación, se presentan los estudios previos relacionados con técnicas de clustering, clasificación y reglas de asociación.

Khribi, Jemni y Nasraoui (2009), presentaron un análisis basados en clustering aplicados a: las preferencias de los estudiantes, la frecuencia con la que los alumnos visitaban los recursos de aprendizaje y el conocimiento de los alumnos; con el fin de obtener un modelo de comportamiento. En el estudio realizado por Abdous, He y Yen (2012), se emplean algoritmos de clustering y regresión para modelar la interacción de los alumnos en los LMSs y relacionándolos con el rendimiento obtenido. El estudio concluye cómo la combinación de la EDM con los análisis tradicionales de la estadística

puede ayudar a profundizar en el comportamiento de los alumnos en las plataformas de aprendizaje.

Con el objetivo de predecir con antelación el rendimiento de los alumnos en un LMS, Lykourantzou et al. (2009), emplearon algoritmos de redes neuronales y clustering. Los resultados obtenidos, indican como los algoritmos de clustering ayudan a reducir el error a la hora de predecir el rendimiento de los alumnos en un estado temprano del proceso de aprendizaje, concretamente cuando la interacción de los alumnos representaba un 30% de la interacción final obtenida. En la misma línea, Romero, Espejo, Zafra, Romero y Ventura (2013), utilizan diferentes algoritmos de clasificación, con diferentes tipos de datos sobre una muestra 438 alumnos repartidos en siete cursos de un LMS, para predecir el rendimiento. Los resultados muestran que no hay un único algoritmo que obtenga la clasificación óptima para todos los casos, destacando la dificultad de predecir el rendimiento de los alumnos según las variables utilizadas. Además, concluyen que en este tipo de estudios se debería proporcionar un modelo de clasificación, tanto preciso como comprensible para los docentes.

Otros estudios persiguen identificar a los alumnos que están en riesgo de abandono a través de su interacción con LMSs. En el caso de Arnold y Pistilli (2012), utilizan un curso online que con un sistema que emplea técnicas de Minería de Datos y análisis estadístico para que el docente pueda comprender la interacción de los alumnos en la plataforma, facilitándole la toma de decisiones. También Essa y Ayad (2012), presentan un sistema basado en modelos predictivos para identificar a los alumnos que están en riesgo de abandono, presentando una serie de acciones al docente para que pueda iniciar la intervención. Por último, Baker, Lindrum, Lindrum, y Perkowski (2015), presentan la integración en un LMS de un sistema basado en modelos predictivos para identificar a este tipo de alumnos, obteniendo entre un 65% y un 70% de éxito, presentando al docente la información mediante un modelo comprensible, dejando una vez más, de mano de éste, la toma de decisiones.

Además, otro objetivo importante es comprender cómo interactúan los alumnos con las diferentes actividades presentes en los LMSs. En este sentido, Govaerts, Verbert, Duval, y Pardo (2012), estudiaron este tipo de interacción a diferentes niveles para proporcionar distintos tipos de visualización de la interacción, tanto a los docentes como a los alumnos. En el estudio realizado por Leony, Pardo, de la Fuente Valentín, de Castro,

y Kloos (2012), presentan una herramienta open source, que representa la interacción de los alumnos en las distintas actividades, bien sea de forma independiente, o por grupos de estudiantes.

Una de las técnicas más empleadas dentro del EDM son las reglas de asociación, que permiten establecer relaciones entre diferentes variables presentes en un conjunto de datos, y las presenta en formas de reglas (Zhang y Zhang, 2002). A continuación, se describen estudios previos relacionados con esta técnica en el ámbito del e-Learning.

En el caso de Merceron y Yacef (2008), generan este tipo de reglas basándose en la interacción realizada por los alumnos en un LMS, presentando diferentes métricas para validar este tipo de reglas. Posteriormente, Romero et al. (2010) presentan un estudio exploratorio para predecir el rendimiento de los alumnos empleando reglas de asociación con clase. También se han empleado para generar herramientas, como es el caso de la presentada por García, Romero, Ventura y De Castro (E. García, Romero, Ventura, y De Castro, 2011), cuyo objetivo es obtener distintos tipos de reglas y que sean los docentes en un ambiente de aprendizaje colaborativo, los que las evalúen y las empleen en sus cursos. Otro tipo de reglas a tener en cuenta, son las reglas poco frecuentes, cuya aparición se debe a la presencia de clases no balanceadas, tal y como demuestra el estudio realizado por Luna, Romero, Romero, y Ventura (2015). En este estudio se analizan este tipo de reglas sobre un LMS para obtener comportamientos de los alumnos que pueden pasar desapercibidos.

En este capítulo se han estudiado los trabajos previos existentes relacionados con los objetivos de la presente tesis doctoral. Se han descrito los modelos más representativos de adaptación, en los que se observa la interacción de tres agentes fundamentales: el alumno, el docente, y el sistema/plataforma. Además, las variables de adaptación están limitadas a las categorías proporcionadas por el modelo y la evolución de los conocimientos de los alumnos. Sin embargo, el análisis posterior de estudios previos relacionados con variables de interacción y la identificación de patrones de comportamiento en LMSs, apuntan la limitación de estos de modelos a la hora de proporcionar mecanismos de adaptación basados en el comportamiento de los alumnos.

# Capítulo 3

## Modelo de adaptación dinámica en LMSs

En este capítulo se presenta un modelo de adaptación del proceso de aprendizaje para LMSs y se describe cómo llevar a cabo su implementación en plataformas Moodle. La clave de este modelo es utilizar un modelo de usuario flexible, en contraposición a los estudios presentados en la sección *Modelos de adaptación*, que permita mejorar el proceso de enseñanza-aprendizaje (E-A) e involucre a los tres agentes fundamentales: el profesor, el alumno y la plataforma.

### 3.1 La interacción de los alumnos en los LMSs

Durante la última década, el desarrollo del e-Learning, b-Learning y el crecimiento de los LMSs (Dagger et al., 2007) ha sido fundamental para ser parte del proceso E-A en la educación superior (Morueta, Rodríguez, y Gómez, 2011). Además, el uso de LMSs como sistemas de aprendizaje exclusivamente online por parte de las universidades es generalizado (García, Ruiz, van Dort, y Pérez, 2010).

Mientras que en el aprendizaje tradicional, los alumnos pueden adoptar una actitud pasiva, cediendo el papel activo al docente, en el aprendizaje en LMSs los alumnos están obligados a desempeñar una actitud activa con el fin de progresar y aprender (Area-Moreira, 2000). Si bien debe considerarse este escenario como algo positivo, el uso de estos sistemas, incorpora una serie de inconvenientes que no deben ser obviados, tales como: sobrecarga cognitiva, distracción y desorientación (Scheiter y Gerjets, 2007). En ocasiones, los alumnos no saben cómo interactuar con la plataforma, dificultando la identificación de la tarea principal, la comprensión de un problema y la toma de decisiones. Esta dificultad, por norma general, suele darse debido a la presencia de demasiada información, generada por una mala organización de los contenidos y una navegación poco eficiente (Ruiz et al., 2008). Por otra parte, variables que forman parte de cómo el alumno desarrolla el aprendizaje, parecen ser condicionantes y determinantes

en el proceso E-A en entornos hipermedia (Jeffrey Alan Greene, Costa, Robertson, Pan, y Deekens, 2010; Moos y Azevedo, 2008).

En esta misma línea, aunque las virtudes en términos motivacionales del uso de TICs en el aprendizaje parece ser una hipótesis ya confirmada, recientes investigaciones muestran que estudiantes de todas las edades tienen dificultades para desplegar sus habilidades metacognitivas, las cuales juegan un rol fundamental en el aprendizaje, cuando éste se lleva a cabo en contextos abiertos, como los LMSs (Azevedo, Behnagh, Duffy, Harley, y Trevors, 2012; Azevedo, Cromley, Moos, Greene, y Winters, 2011; Azevedo et al., 2005). Estos entornos tienen la particularidad de que el alumno es agente activo en el proceso que utiliza para aprender, es decir, puede decidir qué contenidos y rutas de navegación sigue para llegar hasta los resultados de aprendizaje de una manera no-lineal.

Aprender en un LMS requiere un esfuerzo por parte del alumno a la hora de decidir qué va a aprender, cómo y cuánto, si se siente capaz o no, cuándo aumentar o ahorrar esfuerzos, etc. (Azevedo et al., 2005). Muchos de estos interrogantes quedan resueltos durante una clase presencial, pero no siempre, por ejemplo, en una asignatura íntegramente impartida a través de un LMS. En este sentido, los datos de los que se dispone respecto al aprendizaje en educación superior indican que la mayoría de los estudiantes no están adecuadamente preparados para las exigencias de estos contextos de aprendizaje (Azevedo y Feyzi-Behnagh, 2011).

Desde la ciencia cognitiva, la psicología, e incluso desde la inteligencia artificial, se han obtenido resultados que nos muestran que los entornos de aprendizaje con soporte virtual suponen dificultades añadidas al estudiante en disciplinas fundamentales como las ciencias, las matemáticas o las ciencias sociales (Azevedo, 2005). Se han obtenido resultados empíricos convergentes que avalan la idea de que estas dificultades se deben a que éstos no despliegan procesos autorregulatorios claves durante su aprendizaje (Azevedo et al., 2011; Azevedo y Witherspoon, 2009; Quintana, Zhang, y Krajcik, 2005). La motivación y la retroalimentación juegan un papel crucial en el aprendizaje y constituyen un área fundamental en todas las aproximaciones al aprendizaje autorregulado (SRL - self regulated learning) (Butler y Winne, 1995; Valle, Rodríguez, Núñez, Pienda, y Rosário, 2010). Asimismo, los aprendices juegan un rol activo en la generación y uso del feedback, lo cual conlleva implicaciones profundas en la manera en

la que se promociona y evalúa el aprendizaje en soportes virtuales (Nicol y Macfarlane-Dick, 2006).

## 3.2 Los agentes del aprendizaje vía LMS

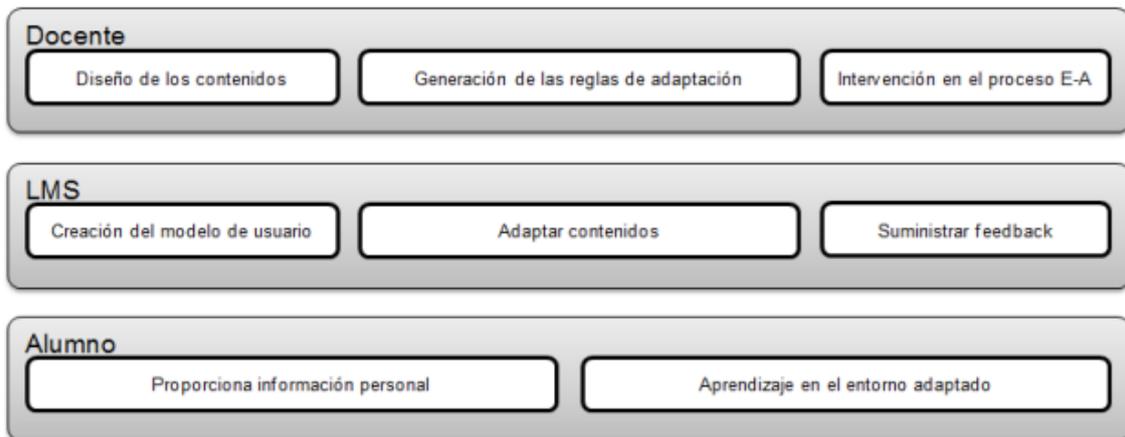
El estudio de los LMSs adaptados es una línea de investigación relativamente reciente que ha generado, sobre todo, conocimiento a nivel básico y no tanto aplicado (Tinajero, Castelo, Guisande, y Páramo, 2011; Vargas, Martínez, y Uribe, 2012). En la actualidad, algunos LMSs comienzan a introducir mecanismos de adaptación (Akbulut y Cardak, 2012). Es el caso de Moodle, que ha implementado procesos basados tanto en la interacción del alumno con la plataforma como en su perfil.

Estos estudios emplean un modelo de usuario estático, donde las variables están predefinidas y el valor asignado a éstas, para un determinado alumno, es común en todos los cursos o elementos del sistema. Este enfoque, poco flexible, imposibilita un mecanismo de adaptación dinámico que permita adecuarse a cada situación concreta de aprendizaje. Un ejemplo sencillo de adaptación dinámica, sería asumir que un alumno que está matriculado en un curso online de matemáticas, no desarrollará la misma interacción en el tema de ecuaciones que en el tema de geometría. Por tanto, aunque las variables a tener en cuenta, así como la forma de calcularlas, no varía, si puede hacerlo el valor de las mismas en cada uno de los ámbitos. Los procesos de adaptación cambiarían, mostrando diferentes contenidos teóricos y/o actividades.

En las siguientes secciones, se propone un modelo teórico de interacción-adaptación cuyo objetivo es apoyar el proceso de E-A, considerando la influencia en el aprendizaje de parámetros dinámicos, no deterministas, que dependen del contexto, características y necesidades del alumno. Estos requisitos, además, delimitan los agentes que participan en el mismo: alumno, docente y sistema o plataforma (LMS en este caso). Estos agentes son comunes en los estudios realizados y analizados los modelos de adaptación, en la sección *Modelos de adaptación*. Los objetivos para cada uno de los agentes (ver figura 4), son las siguientes:

- Docente: Permitirle adaptar los cursos del LMS a las características del alumno, mediante un modelo de usuario flexible, basado en el contexto de aprendizaje.

- LMS: Gestionar el modelo de usuario, con el fin de aplicarlo a la adaptación de contenidos y suministrar feedback a los otros agentes. Facilitando así la toma de decisiones en el proceso de E-A.
- Alumno: Proporcionar información mediante la interacción en la plataforma para iniciar el aprendizaje adaptado.



**Figura 4.** Agentes implicados en el modelo y sus acciones.

Por tanto, es necesario realizar una clasificación genérica de las variables que moldean al alumno para que el docente pueda contribuir a la adaptación. Así, el LMS realiza el proceso de adaptación y proporciona la retroalimentación.

### 3.3 Naturaleza de las variables de adaptación

Si bien trabajos previos proponen realizar una adaptación en base a un conjunto predeterminado de variables, la siguiente propuesta permite a los docentes seleccionar las variables que describen las características, necesidades y contexto de los alumnos, y definir el proceso de adaptación de los contenidos del curso.

En este modelo se diferencian tres tipos de contenidos que se enseñan o aprenden a través del LMS: teóricos, prácticos y aplicados. Del mismo modo que el proceso de E-A difiere en función de sus características, las variables que modulan el proceso de aprendizaje de cada uno de los tipos de contenido, también variarán. De este modo, se ha de diferenciar la adaptación de contenidos puramente teóricos, frente a la adaptación de la puesta en práctica de esos conocimientos. Por ello, el modelo emplea la siguiente clasificación de variables: variables macro contextuales y variables micro contextuales.

Las variables *macro contextuales* son aquellas variables ajenas a la plataforma virtual y que funcionan tanto si la situación de aprendizaje se realiza en una clase magistral como a través de una herramienta de e-Learning. Diferenciando entre:

- Variables de rasgo: no están bajo el control del alumno pero influyen en su aprendizaje. Como por ejemplo: género, edad, etc.
- Variables de estado: dependen de la situación concreta del estudiante en un determinado escenario de aprendizaje. Por ejemplo: comportamiento procrastinador, creencias de autoeficacia, expectativas de logro, metas académicas, etc.

Variables *micro contextuales*: dependientes de la plataforma o de la situación de aprendizaje virtual concreta. Por ejemplo: el detalle de visualización de un curso, la representación del feedback, hojas de estilo, etc.

Una vez definidas las acciones de los diferentes agentes e identificadas la naturaleza de las variables de adaptación, se presenta un modelo de cuatro capas que relaciona todo el proceso de interacción y adaptación.

### 3.4 Las cuatro capas del modelo

El modelo de adaptación está compuesto de cuatro capas (ver figura 5): capa de instrumentos, capa de variables contextuales, capa de procesos de adaptación y capa de retroalimentación.



**Figura 5.** Relación entre capas según la secuencia y los datos que comparten

### 3.4.1 Capa de instrumentos de evaluación

Es la encargada de recopilar la información que permite definir variables dentro del LMS para ser empleadas en la adaptación. Según la naturaleza del instrumento, se clasifica en una de las siguientes categorías:

- Test: autoinformes adaptados a entornos de aprendizaje virtuales validados y extensamente usados por la comunidad científica. Se puede dar el caso de que dichos instrumentos deban ser completados en más de una ocasión por el alumno, dependiendo de si las variables definidas pertenecen a un único contexto o a múltiples (ejemplo: calculadas para cada tema del curso o distintas actividades). Un ejemplo de autoinforme, es el test MSLQ - Motivated Strategies for Learning Questionnaire (Pintrich, Smith, Garcia, y McKeachJe, 1991).
- Históricos: conjunto de datos relacionados con los alumnos, ya sea la información disponible en las plataformas, o los ficheros de logs que registran la interacción del estudiante.

Mientras que los test son relativamente sencillos de interpretar e implementar por un docente, los históricos necesitan la intervención de diferentes procesos para obtener información de la interacción de los alumnos, tal y como se presentará en los capítulos: *Patrones de comportamiento en LMSs* y *Variables de procrastinación en LMSs*.

### 3.4.2 Capa de variables contextuales

Procesa y clasifica la información generada a través de los instrumentos. Su funcionamiento se realiza en dos fases:

- Fase de procesado de variables: las variables definidas en los instrumentos son incorporadas al sistema de manera automática. En algunos casos, el docente debe intervenir, ajustando la asignación de valores a la muestra.
- Fase de procesado de resultados: es la fase encargada de analizar los resultados recogidos por los instrumentos para construir el modelo de usuario.

Estas dos fases proporcionan al LMS un modelo de usuario flexible, ya que el conjunto de variables y sus valores están determinados por el contexto y la posible intervención del docente.

### **3.4.3 Capa de procesos de adaptación**

La capa de procesos de adaptación es la responsable de gestionar y aplicar las reglas descritas por los docentes para adaptar el contenido y navegación del curso al alumno. Las reglas son de tipo condicional y están compuestas de:

- Precondición: el conjunto de valores-variables que se deben cumplir para que se activen las acciones de una regla.
- Acciones: son las encargadas de realizar la adaptación, tanto de los contenidos como de la navegación en el LMS. En su dimensión técnica, las acciones están basadas en la aplicación de los métodos y técnicas de la hipermedia adaptativa (Brusilovsky, 1996, 2001, 2003).

Las reglas, según su objetivo, se clasifican en una de las siguientes categorías:

- Reglas de disponibilidad: indican cómo un alumno interactúa con los contenidos de un curso. Estas reglas determinan si para un alumno un contenido es: (a) accesible, (b) visible pero no accesible o (c) no accesible.
- Reglas de completitud: indican qué acciones se desencadenan cuando se completa un contenido de la plataforma. Ejemplos de acciones son: mostrar un contenido personalizado, enviar un mensaje o cambiar el valor de una variable contextual.

Las reglas de disponibilidad y completitud están interrelacionadas. Completar un contenido puede, a su vez, activar una regla de disponibilidad. Esta reacción en cadena, permite a los docentes establecer diferentes guías de navegación adaptadas a los alumnos.

### **3.4.4 Capa de feedback**

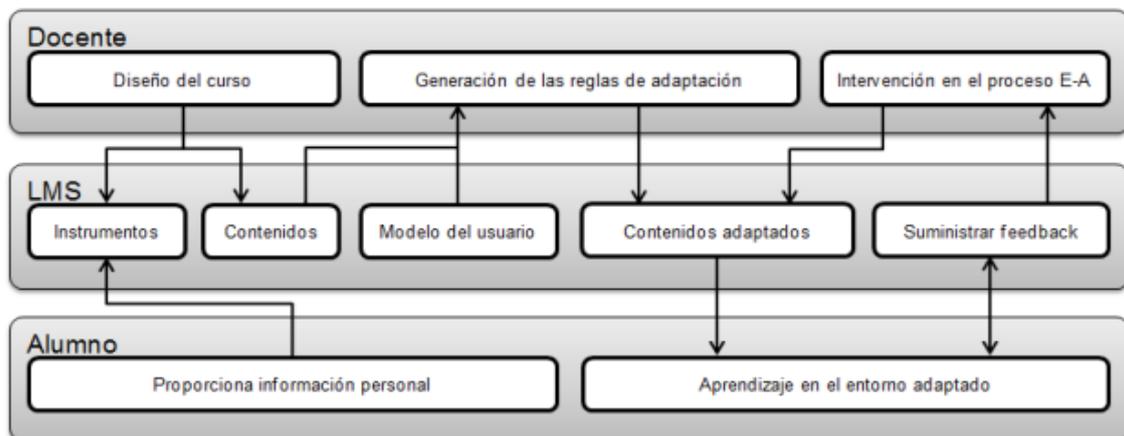
Analiza la interacción del alumno con el LMS y proporciona información al alumno y al profesor sobre el progreso en el entorno de aprendizaje. Se aplican dos niveles de retroalimentación:

- Retroalimentación Docente-sistema-alumno: este tipo de retroalimentación, tiene dos componentes:
  - La retroalimentación que el docente proporciona al alumno acerca de sus resultados como complemento a la evaluación de las tareas.
  - La retroalimentación basada en las reglas de completitud, creadas por el docente y activadas por el sistema, para proporcionar al alumno indicadores de aprendizaje, tal y como propone Duval (2011).
- Retroalimentación Alumno-sistema-docente: el sistema analiza la interacción del alumno con los contenidos del curso y proporciona al docente informes y gráficos del progreso de los estudiantes.

Esta información facilita al docente la toma de decisiones, ayuda a los estudiantes a monitorizar sus logros, y orienta y estimula la reflexión en el proceso de aprendizaje y las competencias adquiridas (Glahn, Specht, y Koper, 2007).

### 3.4.5 Interacción entre los agentes y las capas del modelo

Una vez concretadas las variables, capas, agentes y elementos que posibilitan la adaptación, en la figura 6 se representa la interacción de los agentes con la arquitectura del modelo.



**Figura 6.** Interacción de los agentes implicados con la arquitectura del modelo

En el siguiente apartado, se desarrollará cómo se llevó a cabo la implementación de este modelo en una plataforma Moodle.

### 3.5 Prototipo en la arquitectura Moodle

El modelo ha sido implementado en una plataforma Moodle (versión 2.4) por ser el LMS más utilizado en España en el ámbito de la educación superior (García et al., 2010). Además, desde la versión 2.0, este LMS ha ido añadiendo funcionalidades relacionadas con la adaptación basada exclusivamente en la interacción del alumno con la plataforma, siendo posible reutilizar la base de esta funcionalidad para añadir adaptación basada en características del alumno. Por otra parte, Moodle permite integrar a su sistema módulos (plugins) que amplíen los servicios de la plataforma sin necesidad de modificar el código fuente del sistema.

Por todas estas razones, Moodle ha sido el LMS utilizado para desplegar el modelo de adaptación mediante el desarrollo de dos módulos: *Adaptivetest* y *Adaptivecontrol*. Estos módulos permiten a los docentes desarrollar reglas condicionales de adaptación (tipo IF-THEN) basadas en características del alumno, sobre los elementos de un curso: recurso, actividad y bloque. En la figura 7, se presenta el diagrama de clases de los módulos implementados. En el *Diagramas del prototipo implementado*, puede consultarse más a fondo el desarrollo técnico de cada uno de los módulos.

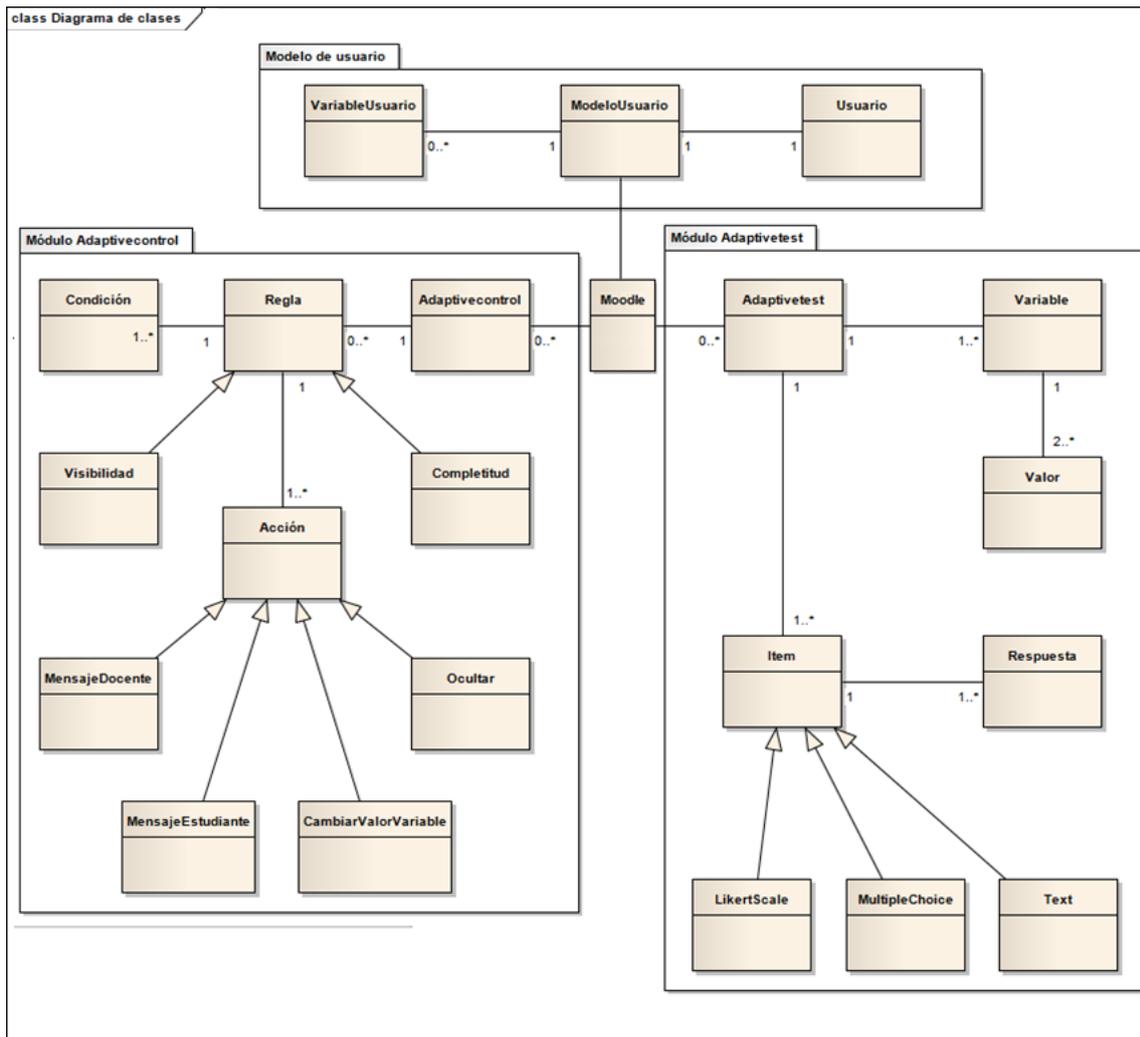


Figura 7. Diagrama de clases de la arquitectura del prototipo.

### 3.5.1 Módulo AdaptiveTest

Este módulo es el encargado de gestionar todo el proceso de obtención de características del alumno, añadiendo a la plataforma un modelo de usuario flexible, relacionándose con las capas del modelo instrumentos de evaluación y variables contextuales. Para ello, permite al docente desarrollar cuestionarios basados en el estándar IMS QTI v2.1 (QTI, 2005), posibilitando generar cuestionarios con ítems de tipo: likert, respuesta múltiple y texto. Una vez generado el cuestionario, el docente puede añadir fórmulas para calcular variables (y valores asociados) en función de los resultados obtenidos en los cuestionarios.

**Figura 8.** Interfaz del módulo AdaptiveTest para añadir variables

Como puede observarse en la figura 8, la interfaz para añadir nuevas variables, consta de tres apartados:

1. En el primer panel, el docente deberá introducir el nombre de la variable.
2. En el segundo panel, el docente puede generar la fórmula con la que se calcularán los valores de la variable. Puede añadir: números, respuestas obtenidas en los ítems del test, operadores aritméticos y paréntesis para denotar preferencia. Según vaya añadiendo elementos, la fórmula se irá representando en la parte inferior del panel.
3. En el tercer panel, el docente podrá discretizar los valores de las variables para mejorar la comprensión de los resultados obtenidos.

Si bien es la única forma de añadir nuevas variables de adaptación, el valor de las mismas puede ser modificado tanto desde este módulo, como desde el módulo AdaptiveControl, como se detalla en el siguiente apartado.

### 3.5.2 Módulo AdaptiveControl

Este módulo es el controlador de todo el proceso de adaptación en la plataforma. Para que los procesos de adaptación sean visualizados por los alumnos, este módulo incluye un formato de curso, un tipo de plugin empleado por Moodle para presentar los contenidos

y los menús de navegación del curso. En relación a las capas presentadas en la sección 3.4, incluiría las capas de procesos de adaptación y la capa de feedback.

El docente puede añadir dos tipos de reglas condicionales basadas en las técnicas y métodos de la hipermedia adaptativa (Brusilovsky, 2001) sobre los diferentes ámbitos del curso (el propio curso, un tema o bloque y un elemento específico). En las precondiciones, se utilizarán tanto las variables condicionales proporcionadas por Moodle, como las obtenidas por el módulo AdaptiveTest. La implementación del modelo, contempla dos tipos de reglas: de visibilidad y de completitud.

### Reglas de visibilidad

Las reglas de visibilidad son las encargadas de gestionar la visibilidad de un elemento, siendo posible: ocultarlo totalmente al alumno o mostrarlo parcialmente, evitando el acceso pero mostrando al alumno que ese elemento, existe. Tal y como se muestra en el ejemplo de la figura 9, ambas posibilidades pueden existir, teniendo mayor peso la regla de visibilidad total. Si no se cumpliese ninguna de las dos opciones, el elemento permanecería oculto.



**Figura 9.** Ejemplo de reglas de visibilidad total y parcial

### Reglas de completitud

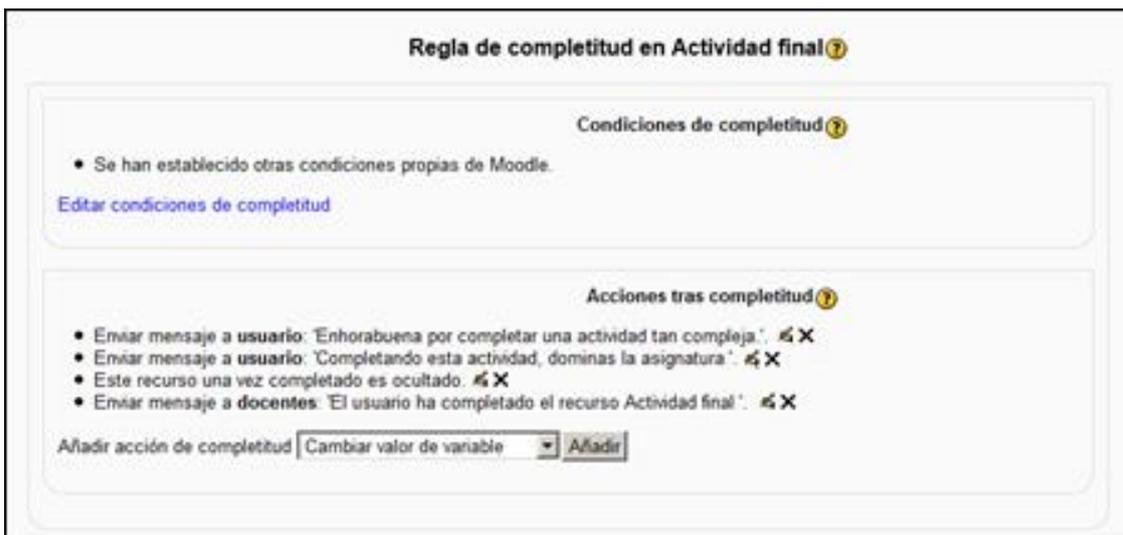
Las reglas de completitud marcan las condiciones que deben cumplirse para considerar un elemento como completado, así como las acciones que se desencadenarán al completar el elemento. En la figura 10, puede observarse que la precondición de la regla permite

utilizar tanto variables obtenidas con el módulo AdaptiveTest, como información la información que proporciona la plataforma sobre el estado de otros elementos.

**Figura 10.** Editor de precondiciones en las reglas de completitud

Una vez establecidas las precondiciones, la regla desencadenará una serie de acciones establecidas por el docente, como puede verse en el ejemplo de la figura 11. Las acciones disponibles son las siguientes:

- Enviar retroalimentación al docente: mediante un mensaje privado detallando que el alumno ha completado el elemento y los resultados obtenidos.
- Enviar retroalimentación al alumno: mediante un mensaje que puede variar según el valor de las variables de adaptación.
- Modificar el valor de una variable de adaptación: es posible modificar el valor de una variable (en cualquiera de los ámbitos: curso, bloque o recurso) según los resultados obtenidos. Por ejemplo: aumentar el nivel de conocimiento sobre un tema específico tras superar el bloque.
- Ocultar el elemento actual: puede ser necesario ocultar el elemento con el fin de aliviar la sobrecarga cognitiva del usuario, o simplemente, para que no vuelva a repetirlo.



**Figura 11.** Acciones disponibles en las reglas de completitud

Por tanto, este tipo de reglas, al modificar el modelo del usuario y el estado del alumno con respecto a los diferentes elementos de la plataforma, puede dar lugar a desencadenar la activación de nuevas reglas de visibilidad, permitiendo al alumno progresar por la plataforma y avanzar en el aprendizaje.

### 3.6 Supuesto teórico: Variables motivacionales

En este capítulo se propone un posible modelo flexible y general, de manera que sea aplicable a diferentes LMSs y útil para cualquier nivel educativo. Sin embargo, resulta especialmente adecuado para educación superior, donde los entornos virtuales de aprendizaje han sido implantados con éxito y los alumnos tienen mayor autonomía en su aprendizaje. A continuación, se describe una aplicación del proceso de adaptación de cara a mejorar la comprensión del modelo. Para ello se han tenido en cuenta contenidos reales de una asignatura del plan de estudios del grado de Psicología. Una de las competencias de la asignatura es que los alumnos aprendan a trabajar de forma autorregulada y entrenen estrategias de aprendizaje interaccionando con los contenidos teóricos y prácticos disponibles a través del LMS. Empleando el modelo propuesto, se adaptan dichos contenidos en función de la percepción de autoeficacia y el tipo de meta que guía el proceso de aprendizaje de cada alumno.

Se han seleccionado variables relacionadas con la motivación porque juega un papel crucial en el aprendizaje y constituye un área fundamental en todas las aproximaciones al aprendizaje autorregulado (Valle et al., 2010). En la ya clásica metáfora del Will y Skill

se representa la habilidad y la intención como ambas caras de una misma moneda (Pintrich y De Groot, 1990), siendo en esta última donde encajarían las dos variables con las que se plantea utilizar procesos de adaptación. Así mismo, los estudiantes autorregulados se caracterizan por creencias motivacionales y actitudes adaptativas, como por ejemplo altos niveles de competencia percibida o autoeficacia, y orientación a metas de aprendizaje (Pintrich, 2000; Schunk y Ertmer, 2000). Quedando definidas las creencias de autoeficacia como las percepciones de los sujetos sobre sus propias capacidades para enfrentarse a un determinado aprendizaje o resolver una tarea; y los objetivos o metas de estudio como aquellas que determinan la implicación y las estrategias utilizadas para la realización de una tarea (Zimmerman, 1989; Zimmerman y Schunk, 1989).

### 3.6.1 Instrumentos y variables

Una vez definido el interés de las variables motivacionales, se delimitan las variables en función de las cuales se adapta el entorno al alumno: *Autoeficacia Percibida* y *Metas de Estudio* (ver tabla 1).

Instrumento	Variable	Posibles valores
MSLQ	Autoeficacia macro	Baja – Media – Alta
MSLQ	Metas de Estudio	Logro – Aprendizaje – Combinada
Formulario	Autoeficacia micro	Baja – Media – Alta
Histórico del LMS	Contenido/tarea completada	Completado – No completado

**Tabla 1.** Instrumentos de medida, variables de adaptación y sus valores

La *Autoeficacia Percibida*, a su vez, tendría dos niveles, macro y micro, atendiendo a las diferencias encontradas en la literatura entre *General Self-efficacy* y *Specific Self-efficacy* (Agarwal, Sambamurthy, y Stair, 2000; Schunk, 1995).

- Autoeficacia Macro: relativa a cuán eficaces se perciben los sujetos, en general, para aprender en el entorno virtual. Esta variable se mide a través de la subescala de creencias de autoeficacia del MSLQ - Motivated Strategies for Learning Questionnaire (Pintrich et al., 1991), compuesta por 8 ítems a los que el sujeto debe dar una puntuación de 1 a 7 en función del ajuste a su situación personal. La formulación de los ítems ha sido ligeramente modificada para ajustarlos a las

peculiaridades del entorno virtual tal como se ha hecho con anterioridad en la literatura (Moos y Azevedo, 2008).

- Autoeficacia Micro: relativa a cuán eficaces se perciben los sujetos, en particular, para enfrentarse a determinados contenidos o tareas. Esta variable se evalúa a través de un único ítem que pregunta al sujeto cómo de eficaz se percibe para afrontar unos contenidos específico del tema o una tarea concreta en una escala de 1 a 7.

La variable *Metas de Estudio*, asimismo, tendría dos niveles, *Orientación a Metas Extrínseca* y *Orientación a Metas Intrínseca* (Valle et al., 2003; Valle et al., 2010). En función de ella se clasifica a los sujetos a través de la subescala de componente de valor del MSLQ (Pintrich et al., 1991).

- *Orientación a Metas Extrínsecas*: este tipo de metas se describen como aquellas que llevan al individuo a realizar una determinada acción para la consecución de otros motivos no relacionados con la actividad, sino con la consecución de otras metas que en el campo académico suelen ser: obtener buenas notas o recompensas materiales, lograr reconocimiento social, evitar el fracaso, etc.
- *Orientación a Metas Intrínsecas*: se vincula este tipo de metas a aquellas acciones realizadas por el interés que genera la propia actividad, no como un medio para alcanzar otras metas.

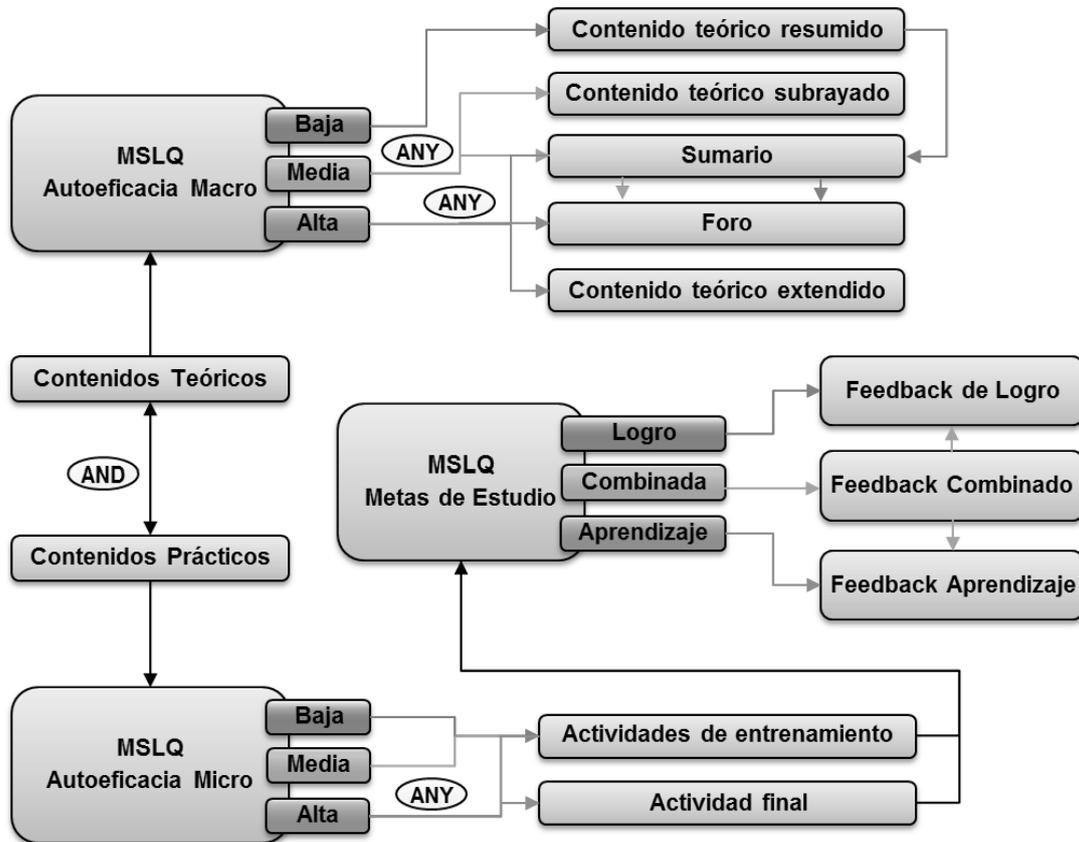
La variable *Metas de Estudio* es medida a través de 8 ítems (4 correspondientes a Metas Extrínsecas y otros 4 para Metas Intrínseca) a los que el sujeto debe dar una puntuación de 1 a 7 en función del grado de ajuste a su situación personal. La formulación de los ítems también ha sido ligeramente modificada para ajustarse a las peculiaridades de los entornos virtuales.

La formulación de los ítems planteados en este ejemplo, puede consultarse en la sección: *Items del MSLQ del supuesto teórico*.

### **3.6.2 Proceso de adaptación**

En la figura 12, se muestra el proceso de adaptación aplicado a los contenidos de la asignatura. Según el valor que tomen las variables, la interacción del alumno con los

contenidos (teóricos/prácticos) varía, ofreciéndole la posibilidad de elegir diferentes modalidades de contenido o guiándolo a través de una secuencia determinada.



**Figura 12.** Representación teórica del proceso de adaptación y del de feedback.

Para comprender el ejemplo, es necesario conocer previamente los elementos susceptibles de adaptación que conforman la asignatura. Por un lado, los contenidos puramente teóricos con tres niveles de complejidad: contenido teórico extendido, contenido teórico subrayado y contenido teórico resumido. Además, se cuenta con sumarios de cada una de las unidades de contenido con la información indispensable para el alumno. Por otro lado, los contenidos aplicados a la práctica; para ello se cuenta con un banco de tareas que iteran en función de su grado de complejidad y de los resultados del alumno. Finalmente, el curso se completa con recursos alternativos como foros, audios, videos, etc. que se incluyen en cada tema como complemento de los contenidos teórico-prácticos.

Una vez delimitados los elementos disponibles en el curso, el LMS calcula las posibles rutas adaptativas que puede seguir un alumno dentro de esta asignatura. Por ejemplo, si

el alumno se enfrenta al contenido teórico, y su valor en la *autoeficacia macro* es “bajo”, las reglas de disponibilidad obligan a que complete los contenidos en el siguiente orden: “contenido teórico resumido” y “sumario del tema”. Sin embargo, si el valor de la *autoeficacia macro* es “medio”, el alumno elige qué contenido completar primero, “contenido teórico subrayado” o bien “sumario del tema”. Por último, si la *autoeficacia macro* es “alta”, se le añade la posibilidad de acceder al “contenido teórico extendido”. Solo cuando el alumno complete los contenidos teóricos se le redirige al foro para que pueda participar en él.

En el caso de las tareas, la adaptación se lleva a cabo en base a la variable *autoeficacia micro*. En esta fase se pretende asegurar, al menos, algún éxito inicial a todos los estudiantes, especialmente a aquellos que parten de un nivel de autoeficacia micro bajo. Todos los alumnos, independientemente de que partan de un nivel alto, bajo o alto, deben de finalizar en la fase de resolución de tareas con un nivel alto, es decir, con la percepción de que pueden resolver la tarea planteada eficazmente y demostrar que así lo hacen. Para ello, el LMS combina las puntuaciones en los ítems de autoeficacia micro y los resultados en cada tarea concreta, y calcula en tiempo real la ruta para la resolución de las tareas prácticas en función del nivel de complejidad más adecuado.

### 3.6.3 Adaptación del feedback

La adaptación del feedback se realiza a dos niveles:

- Docente-sistema-alumno: el alumno recibe mensajes personalizados donde se le indica el progreso de su aprendizaje, así como las competencias adquiridas. El contenido de estos mensajes, está adaptado según la variable *Metas de Estudio*. Por ejemplo, si el alumno obtiene una puntuación que le sitúa en metas de aprendizaje, se le retroalimenta reforzando las competencias que ha adquirido al superar un determinado contenido. Si por el contrario es un estudiante orientado a metas de logro, la retroalimentación resalta la puntuación obtenida al superar ese contenido. A aquellos aprendices que se guían por metas combinadas se les da un feedback también combinado de aprendizaje y logro. La retroalimentación de los sujetos con metas de logro o con metas de aprendizaje se intercala también con feedback combinado en consonancia a los estudios sobre metas, en los que se

observa que una combinación de ambas parece ser la orientación que optimiza los resultados de aprendizaje (Rodríguez et al., 2001; Valle et al., 2003, 2009).

- Alumno-sistema-docente: a través de informes y gráficos, el docente dispone de la información acerca del progreso individual y colectivo de los alumnos en cada tema (Duval et al., 2012). La información incluye los contenidos visitados, las actividades realizadas, los tiempos y periodos de actividad, el rendimiento, la variación de los valores en la autoeficacia y las metas, etc.; una amplia variedad de indicadores inter e intra sujeto indicadores que permiten al docente conocer el proceso de aprendizaje del alumno y no solo su producto.

La retroalimentación refuerza la monitorización y favorece la adaptación del proceso de enseñanza-aprendizaje (E-A), permitiendo que el docente establezca nuevas estrategias instruccionales, y que el propio estudiante oriente el aprendizaje en consonancia a sus metas de estudio.

### **3.7 Discusión**

En este estudio presentamos un modelo teórico de adaptación de los entornos de aprendizaje a los estudiantes. Este objetivo viene motivado principalmente por las dificultades añadidas que experimentan los estudiantes cuando aprenden en entornos de aprendizaje hipermedia o cuándo el aprendizaje se lleva a cabo en contextos abiertos, como los LMSs (Azevedo et al., 2012, 2011; Scheiter y Gerjets, 2007).

El estudio está basado en tres premisas fundamentales: el alumno es sujeto activo y dinámico en el aprendizaje que tiene lugar en entornos virtuales, el profesor ha de poder andamiar y adaptar ese proceso de aprendizaje, las plataformas deben poder adaptar sus contenidos y navegación, y proporcionar feedback en tiempo real del proceso de E-A.

A partir de los supuestos anteriores, se ha desarrollado un prototipo que soporta un modelo teórico de adaptación fundamentado en un modelo de usuario dinámico, un sistema de reglas diseñadas por el docente, y un proceso automático de adaptación y retroalimentación que realiza el LMS. Tradicionalmente, el modelo de usuario, así como el proceso de adaptación en los sistemas, era estático y poco flexible. La alternativa propuesta permite a los docentes conocer y seleccionar las variables que delimitan las características, necesidades y contexto de los alumnos, y definir las reglas de adaptación.

El LMS es el agente encargado de regular el proceso de adaptación a través de técnicas de la Hipermedia Adaptativa (Brusilovsky, 1996, 2001), además de ofrecer feedback sobre el proceso de aprendizaje tanto a los profesores como a los estudiantes (Duval, 2011), analizando la interacción de los alumnos mediante técnicas de Minería de Datos (Romero et al., 2008).

La implementación del prototipo ha sido realizada sobre la arquitectura Moodle, debido a su diseño modular. Para tal fin, se han desarrollado dos módulos: el primero, AdaptiveControl, gestiona los procesos de adaptación y feedback, y AdaptiveTest; y el segundo, AdaptiveTest, que gestiona la implementación de instrumentos de evaluación y las variables asociadas, con el fin de emplearlas en la adaptación.

# Capítulo 4

## Patrones de comportamiento en LMSs

En el anterior capítulo, se presentó un modelo con el fin de mejorar el proceso de enseñanza-aprendizaje, así como su implementación en una plataforma Moodle y un ejemplo teórico de adaptación. Sin embargo, a la hora de llevarlo a la práctica, y asegurarse de que realmente supone una mejora del proceso E-A, es necesario diferenciar entre lo que opinan de sí mismos los alumnos (a través de los autoinformes, por ejemplo), de lo que realmente son, o de lo que realmente sienten; bien sea en términos de autoeficacia u otras variables. En este sentido, son conocidas las limitaciones de los autoinformes para medir, especialmente procesos, como lo es el aprendizaje (Núñez, Solano, González-Pianda, y Rosário, 2006; Pike y Kuh, 2005; Winne y Perry, 2000).

Por eso, en este capítulo, analizamos la interacción de los alumnos en un LMS con el fin de comprender mejor su comportamiento y obtener qué variables pueden modelar ese tipo de comportamiento. De esta forma, podría complementarse el modelo teórico anteriormente presentado, así como el supuesto teórico presentado, vinculando las variables de los autoinformes, con las variables de comportamiento en el LMS probadas empíricamente.

### 4.1 Introducción

Las plataformas de aprendizaje están teniendo un fuerte impacto en la adquisición de conocimiento, y los estudios empíricos desde la ciencia cognitiva y las ciencias de la computación están estudiando esta temática desde diferentes perspectivas (Azevedo y Alevan, 2013). Sin embargo, los hallazgos en este campo, revelan que no todos los alumnos se benefician de las oportunidades de aprendizaje que brindan los LMSs (Lust, Collazo, Elen, y Clarebout, 2012) y el manejo del alumno en el uso de los LMSs no se puede dar por supuesto (Lust, Vandewaetere, Ceulemans, Elen, y Clarebout, 2011). Existen abundantes estudios empíricos que sugieren que los alumnos no adaptan

satisfactoriamente su comportamiento a las exigencias de los entornos de aprendizaje complejos, como es el caso de los LMSs (Azevedo y Feyzi-Behnagh, 2011). Además, sistemas como los LMSs requieren un mayor esfuerzo por parte del alumno a la hora de decidir: qué, cómo y cuánto aprender; cuánto tiempo emplear; cuándo abandonar y cambiar estrategias de aprendizaje: cuándo realizar un mayor esfuerzo; entre otras (Azevedo et al., 2005).

Por otra parte, en la enseñanza tradicional, los docentes pueden obtener fácilmente una visión sobre la forma en la que los alumnos trabajan y aprenden. En los LMSs, sin embargo, es más difícil para los docentes entender cómo se comportan los alumnos y cómo aprenden en el sistema (Graf y Liu, 2009), puesto que estos entornos proporcionan datos de la interacción a muy bajo nivel. Debido a que las actividades de los alumnos son cruciales para un aprendizaje online efectivo, es necesario buscar métodos empíricos para comprender mejor los patrones de comportamiento en los entornos virtuales (Neuhauser, 2002).

Además, explorar cómo los diferentes patrones de comportamiento de los alumnos en los LMSs están relacionados con el rendimiento final, podría ser muy útil en el diseño de entornos virtuales de aprendizaje adaptados (Bra y Calvi, 1998; Brusilovsky, 2003). Recientemente, ha aparecido una nueva tendencia a la hora de diseñar este tipo de entornos, basándose en los datos de la interacción realizada por los alumnos con el sistema a bajo nivel de granularidad (Romero et al., 2009; Romero et al., 2008). El objetivo principal de esta nueva tendencia es refinar al máximo el andamiaje que el sistema proporcionada a cada alumno. Tal y como evidenciaron previamente Dabbagh y Kitsantas (2005, 2013), andamiar la adquisición de los procesos SRL (Self-Regulated Learning o Aprendizaje Autorregulado) del estudiante es especialmente importante en los cursos online porque, a los alumnos, frecuentemente se les pide que completen tareas de aprendizaje con poco o nulo soporte, teniendo que ser los alumnos altamente autoregulados.

En este capítulo se investiga la interacción de los alumnos con los LMSs desde el punto de vista de la Minería de Datos Educativa (EDM) que, a su vez, está relacionada con la adaptación de los entornos de aprendizaje. Variables tales como el esfuerzo, tiempo de trabajo, y la procrastinación, pueden ser calculadas a través de los logs de un LMS para ayudar a responder estos tipos de preguntas: ¿Pueden los estudiantes adaptarse a las

exigencias de las plataformas de aprendizaje actuales? ¿Tiene relación su habilidad para adaptarse con el rendimiento obtenido? Profundizando más, ¿podemos adaptar estas plataformas online a las características de los estudiantes? ¿Necesitas todos los alumnos adaptación o simplemente recomendaciones? Estas preguntas, y otras similares, surgen cuando reflexionamos acerca de a dónde nos dirigimos en el campo de las plataformas de aprendizaje online y, es más, hacia dónde estamos intentando guiar a los alumnos. En resumen, sería valioso obtener un conocimiento más amplio del comportamiento de los alumnos en este tipo de entornos y entender cómo esto afecta a su rendimiento, que a su vez, contribuirá a la mejora del proceso de aprendizaje. Para este objetivo, la EDM es una de las líneas de investigación más recientes que puede ayudarnos a entender mejor la interacción del usuario y los sistemas de información (Agosti, Crivellari, y Di Nunzio, 2012).

Los trabajos previos analizados en la sección *Minería de Datos y la interacción en los LMSs*, están realizados con técnicas similares a las que se emplean en este capítulo. Sin embargo, la mayoría se despliegan sobre un contexto experimental, empleando pequeños intervalos de tiempo, alejados de lo que supone un contexto real de aprendizaje. La aportación de este trabajo, es que los análisis presentados a continuación, sin embargo, están desarrollados sobre un contexto real, empleando materiales del currículo oficial de los estudiantes durante todo un semestre.

## 4.2 Objetivos del estudio

En las siguientes secciones, se extraen diferentes grupos de alumnos con un comportamiento similar en un LMS Moodle y se relacionan con diferentes niveles de rendimiento. Los datos se han obtenido de un curso cuya duración es de 11 semanas, y forma parte de una asignatura obligatoria del grado de Psicología de una Universidad en el Norte de España. El objetivo principal de estos análisis es contribuir al conocimiento sobre la interacción de los alumnos en un LMS y su hipotético valor para predecir el rendimiento. En base a este propósito, se plantean las siguientes preguntas de investigación:

- ¿Existen diferentes patrones de comportamiento relacionados con el esfuerzo y la procrastinación entre los alumnos cuando aprenden a través de un LMS en un contexto real?

- ¿En qué medida las variables obtenidas de los logs de Moodle para configurar los patrones son igualmente adecuadas para configurar los clusters?
- ¿Existe relación entre los patrones de esfuerzo y procrastinación obtenidos de los logs de Moodle con el rendimiento final?

Para responder a estas preguntas, una vez que los alumnos finalizaron la asignatura, analizamos el rendimiento final obtenido, así como los logs del LMS obtenidos a través del registro proporcionado por Moodle.

El resto del estudio está organizado de la siguiente manera. Tras plantear las preguntas de investigación, se presenta la metodología dividida en tres fases. En la primera fase, se describen los participantes y el procedimiento, además del proceso de extracción de variables. En la segunda fase, se realiza un análisis basado en clustering para agrupar a los alumnos, y en la tercera fase, se realiza una ANOVA para observar la hipotética diferencia inter-clúster. Por último, se muestran los resultados y se discuten relacionándolos con cada una de las preguntas de investigación.

## 4.3 Metodología

### 4.3.1 Participantes y procedimiento

El conjunto de datos empleado en el estudio ha sido obtenido de curso basado en Moodle 2.0 con un total de 140 participantes matriculados en el grado de Psicología en una universidad al Norte de España (edad media = 20,23; SD= 1,01; mujeres: 83%). El estudio tuvo lugar durante el curso académico 2012-2013. El fichero de log de la interacción de los alumnos es generado automáticamente por Moodle (Cole y Foster, 2007).

La tarea a realizar, denominada eTraining for Autonomous Learning-eTRAL (Cerezo et al., 2010; Núñez et al., 2011), forma parte de una asignatura obligatoria de tercer curso. A los alumnos se les pidió participar en un entrenamiento online sobre el aprendizaje autorregulado y estrategias de estudio, relacionado con la temática de la asignatura, y tenía que ser completado fuera de las horas de docencia. El entrenamiento está compuesto de 11 unidades diferentes abriéndose automáticamente, una por semana. El contenido de las unidades estaba basado en un conjunto de estrategias de aprendizaje relacionadas con la autorregulación.

Basándose en la diferenciación clásica de los tres tipos de conocimiento: declarativo o conceptual, procedimental y condicional (Biggs y Biggs, 2004; Brown, 1987; Jacobs y Paris, 1987; Schraw y Moshman, 1995), cada unidad estaba compuesta de tres tipos de contenidos asociados a los tipos de conocimiento:

- Conocimiento a nivel declarativo: Contenidos teóricos - descripción, información y conocimiento de cómo poner en práctica la estrategia “aprender a aprender” o las estrategias presentadas en la unidad.
- Conocimiento a nivel procedimental: Tareas prácticas - donde los estudiantes ponían en práctica el conocimiento declarativo.
- Conocimiento a nivel condicional: Foros de discusión - donde los estudiantes debatían sobre cómo habían usado o de cómo usar la estrategia, o estrategias, de la unidad semanal en diversos contextos.

A los estudiantes se les daba un punto extra en el rendimiento final si completaban al menos un 80% de las unidades. Es crucial especificar las actividades obligatorias para dar por completada cada unidad con el fin de explicar las posibles respuestas a los interrogantes planteados en la investigación. Así pues, las actividades obligatorias para completar cada unidad, consistían en enviar la actividad práctica y escribir al menos una opinión en el debate del foro. Las actividades aconsejadas para cada unidad, consistían en comprender el contenido teórico y ponerlo en práctica durante la actividad práctica, así como compartir su experiencia en el foro (de manera independiente al debate). Se estimó que para completar cada unidad se necesitaban una media de 2-2,5 horas de trabajo semanal, incluyendo una lectura comprensiva de la teoría, la actividad práctica y el foro.

### **4.3.2 El proceso de extracción de variables**

Tras finalizar la experiencia con eTRAL, se analizó el fichero de log (un ejemplo de fichero log puede verse en la figura 13) generado por la interacción de los estudiantes en el LMS. Es importante destacar que se filtraron del fichero de log aquellas acciones que estaban relacionadas con las variables empleadas, descartando el resto. El LMS almacena automáticamente 76 acciones (en la sección *Diagramas del prototipo implementado* están disponibles todas las acciones que almacena Moodle), y tal y como en otros estudios (J. H. Kim et al., 2014), se han seleccionado 12 acciones para generar 6 variables.

**Live logs from the past hour**

Displaying 25 records

Time	IP Address	Full name	Action	Information
Tue 5 September 2006, 01:33 AM	70.109.156.137	Teacher Demo	course report live	Moodle Features Demo
Tue 5 September 2006, 01:33 AM	128.173.54.50	Student Demo	resource view	How to install the Features
Tue 5 September 2006, 01:33 AM	128.173.54.50	Student Demo	course view	Moodle Features Demo
Tue 5 September 2006, 01:32 AM	128.173.54.50	Student Demo	hotpot view	3
Tue 5 September 2006, 01:32 AM	128.173.54.50	Student Demo	hotpot view	4
Tue 5 September 2006, 01:32 AM	128.173.54.50	Student Demo	hotpot view all	
Tue 5 September 2006, 01:32 AM	128.173.54.50	Student Demo	course view	Moodle Features Demo
Tue 5 September 2006, 01:30 AM	72.147.138.34	Admin User	calendar add	Test Results on Tuesday
Tue 5 September 2006, 01:30 AM	72.147.138.34	Admin User	forum view discussion	Linear Equations
Tue 5 September 2006, 01:29 AM	72.147.138.34	Admin User	course view	Moodle Features Demo
Tue 5 September 2006, 01:29 AM	72.147.138.34	Admin User	forum add discussion	Linear Equations
Tue 5 September 2006, 01:28 AM	72.147.138.34	Admin User	course view	Moodle Features Demo
Tue 5 September 2006, 01:25 AM	70.109.156.137	Teacher Demo	user view	Teacher Demo
Tue 5 September 2006, 01:25 AM	70.109.156.137	Teacher Demo	course report particip	4
Tue 5 September 2006, 01:18 AM	70.109.156.137	Teacher Demo	course report live	Moodle Features Demo

**Figura 13.** Estructura de los logs en la plataforma Moodle.

Estas variables (ver tabla 2), son las que se consideraron más útiles a la hora de representar el rendimiento de los alumnos en el programa eTRAL de la plataforma. Algunas variables se obtuvieron directamente de los logs; otras se calcularon mediante consultas agregadas (Talavera y Gaudioso, 2004). Por último, algunas variables se calcularon mediante una operación aritmética simple, como puede observarse en la tabla 3, la variable *días entrega* se calculó restando la fecha en la que el alumno subió la tarea (acción “submit” proporcionada por el fichero de log) a la fecha en la que el alumno accedió por primera vez a la unidad (acción “view” proporcionada también por el fichero de log).

Otras variables se extraen fácilmente mediante procedimientos similares. Por ejemplo, el tiempo que pasa un alumno en el contenido teórico o el tiempo que pasa un alumno en la actividad práctica. Particularmente, la variable tiempo dedicado a la actividad es un indicador fiable de en el estudio porque el módulo quiz de Moodle permite establecer un tiempo límite para cada actividad.

El número de palabras escritas en el foro, en este caso, se seleccionó como indicador de la calidad de la respuesta en el foro de debate. Las respuestas escritas por los alumnos fueron analizadas de forma manual por el profesor durante el desarrollo del curso. Así se evitaron posibles respuestas genéricas o vacías de contenido relacionado.

Nombre	Descripción	Información adicional
<b>Variables de esfuerzo y tiempo de trabajo</b>		
<i>Tiempo actividad</i>	Tiempo total dedicado a las actividades prácticas.	Los alumnos tienen 15 días para completar la actividades (cuestionarios).
<i>Tiempo teoría</i>	Tiempo total dedicado a los contenidos teóricos.	Los alumnos tienen 15 días para acceder a los contenidos teóricos.
<i>Tiempo foro</i>	Tiempo total dedicado a los foros.	Los alumnos tienen 15 días para acceder y participar en los foros.
<i>Palabras foro</i>	Número de palabras escritas en los foros.	A los alumnos no se les pide un máximo o mínimo de palabras.
<i>Acciones relevantes</i>	Número de entradas en el log relacionadas con las acciones seleccionadas.	Acciones tales como: inicio de sesión, cierre de sesión, ver el calendario, etc, se descartaron.
<b>Procrastinación</b>		
<i>Días entrega</i>	El tiempo que tardan en entregarse las tareas desde que está disponible la unidad.	Los estudiantes tienen 15 días para completar las tareas.

**Tabla 2.** Categorización y descripción de las variables seleccionadas.

Las variables seleccionadas para configurar los patrones de comportamiento de los alumnos pueden clasificarse en dos grupos, teniendo en cuenta lo que representan en un nivel de granularidad más alto.

*Variables relacionadas con el esfuerzo y el tiempo de trabajo.* Uno de los problemas más desafiantes en este campo es dar significado a los datos en el contexto de aprendizaje. Para abordar esta particularidad, se han clasificado dentro de este grupo, las siguientes variables: *tiempo actividad*, *tiempo teoría*, *tiempo foro*, *acciones relevantes*, y *palabras foro*.

*Variables relacionadas con la procrastinación.* El número de días que pasan hasta que entregan la actividad (*días entrega*), podría ser un indicador indirecto de la procrastinación de los alumnos.

El método de extracción de las variables anteriores, está descrito en la tabla 3. Además, según Formann (1984), el número de variables necesarias para configurar estos patrones o clusters, deben seguir la fórmula  $2^m \leq N$ , donde  $m$  es el número de variables y  $N$  es el tamaño de la muestra.

Variable	Método de extracción
<i>Tiempo actividad</i>	Suma de los tiempos (minutos) sobre la actividad en las acciones: quiz view, quiz attempt, quiz continue attempt, quiz close attempt.
<i>Tiempo teoría</i>	Suma de los tiempos (minutos) sobre el recurso en las acciones: resource view
<i>Tiempo foro</i>	Suma de los tiempos (minutos) sobre el foro en las acciones: forum view, forum view discussion, forum add discussion, forum add reply, update post y forum add post.
<i>Palabras foro</i>	Extracción directa de los foros.
<i>Acciones relevantes</i>	El contador total de las acciones contempladas en las variables anteriores.
<i>Días entrega</i>	La diferencia (en días) entre la fecha del primer quiz close attempt y la fecha de apertura de la unidad.

**Tabla 3.** Proceso de extracción de las variables empleadas.

Por último, se utilizó el *rendimiento final* obtenido por los alumnos. En este estudio, se considera un índice del rendimiento general porque no es simplemente la puntuación obtenida en las actividades completadas en eTRAL (que tienen un peso de 1 sobre 10 en la nota final), también es la suma de la puntuación obtenida en el examen final de la asignatura.

### 4.3.3 Análisis de datos

Los datos se analizaron en diferentes fases. Primero, se aplicó clustering mediante un algoritmo óptimo para conjuntos de datos grandes, el expectation-maximization o EM (Dempster, Laird, y Rubin, 1977), permitiendo al algoritmo calcular automáticamente el número de clusters óptimos con fines exploratorios. El EM calcula el número de clusters óptimos basándose en probabilidades y, como se observa en estudios previos, funciona bien en este contexto (Lopez, Luna, Romero, y Ventura, 2012). Seguidamente, se buscó una solución similar obtenida mediante el algoritmo k-means con el fin de confirmar los

resultados obtenidos. Para emplear este algoritmo, es necesario indicar el número de clusters que se desean obtener. Adicionalmente, para determinar el éxito del k-means, se utilizó el Método del Codo para representar el error de la suma de los cuadrados en función del número de clústers, y encontrar así, el “codo” en la gráfica (Brooks, Thompson, y Kovanović, 2016).

El objetivo de estos dos pasos es obtener una solución basada en clusters que sea coherente entre el EM y el k-means. En este contexto, el análisis de clusters se utilizó para agrupar a los alumnos según su comportamiento en el LMS. A través del clustering, se busca obtener una alta similitud intra-cluster y maximizar las diferencias entre ellos (Manly, 2004). Para este caso, los algoritmos previamente descritos se utilizaron tal y como se han empleado en trabajos previos (Romero, Ventura, Espejo, y Hervás, 2008; Witten et al., 1999). Además, debido a que las seis variables empleadas en el clustering, tienen diferentes escalas, la representación gráfica de los grupos se presenta de forma tipificada ( $M = 0$ ,  $SD = 1$ ). Finalmente, y como último paso, se emplearon ANOVAs para observar si había diferencias inter-clusters, la importancia de cada variable en la configuración del cluster, y la validez predictiva de estos clusters para predecir el rendimiento final. Para determinar el peso de cada variable en la configuración del cluster, así como la relación de cada clusters y los rendimientos finales de los estudiantes y la significación estadística, el análisis ANOVA proporciona el tamaño del efecto mediante la eta cuadrado parcial y los valores de la  $d$  de Cohen. Para interpretar el tamaño del efecto, se utilizó el criterio clásico establecido por Cohen (1988), que dijo que  $\eta^2_p = 0,01$  ( $d = 0,20$ ) es un efecto pequeño,  $\eta^2_p = 0,059$  ( $d = 0,50$ ) es un efecto mediano, y  $\eta^2_p = 0,138$  ( $d = 0,80$ ) es un efecto grande. Por último, se hicieron análisis con la prueba T para analizar las diferencias de rendimiento entre los clusters.

## 4.4 Resultados

### 4.4.1 Estadísticos descriptivos

Los resultados se explican siguiendo las preguntas de investigación establecidas en la sección *Objetivos del estudio*. En la tabla 4, se presentan los estadísticos descriptivos obtenidos (correlación de Pearson, media, desviación típica, mínimo y máximo) para toda la muestra.

	<i>Tiempo actividad</i>	<i>Días entrega</i>	<i>Palabras foro</i>	<i>Tiempo teoría</i>	<i>Tiempo foro</i>	<i>Acciones relevantes</i>	<i>Rendimiento final</i>
<i>Tiempo actividad</i>	-						
<i>Días entrega</i>	-0,283**	-					
<i>Palabras foro</i>	0,210**	-0,104	-				
<i>Tiempo teoría</i>	-0,078	-0,158	0,247**	-			
<i>Tiempo foro</i>	0,183*	-0,265**	0,469**	0,310**	-		
<i>Acciones relevantes</i>	-0,368**	-0,071	0,283**	0,539**	0,441**	-	
<i>Rendimiento final</i>	0,447**	-0,352**	0,195*	0,049	0,096	-0,161	-
M	10,151	3,800	95,792	5,933	9,911	5,399	6,168
SD	5,525	2,606	40,924	3,018	5,636	0,774	1,919
Mínimo	1,73	0	0	0	0	2,82	0
Máximo	25,73	14	232	12,91	37,91	6,55	10

Nota: \* p < 0,01; \*\* p < 0,001.

**Tabla 4.** Correlación de Pearson, media, desviación típica, mínimo y máximo

Una vista preliminar a la matriz de correlación muestra la existencia de relaciones entre variables en la mayoría de los casos ( $KMO = 0,622$ ; test de esfericidad de Bartlett:  $\chi^2(21) = 228,265$ ;  $p < 0,001$ ). Como se esperaba, las variables relacionadas con el tiempo dedicado en el LMS se relacionan positivamente excepto *tiempo teoría* y *tiempo*

*actividad*. Vale la pena destacar la relación negativa entre *días entrega* y el resto de variables, indicando que a más tiempo dedican los alumnos a trabajar en la teoría, foros o actividades, menos tiempo tardan en entregar. Finalmente, se observa una relación negativa entre *días entrega* y *rendimiento final*, y las dos variables relacionadas positivamente con *rendimiento final* son *tiempo actividad* y *palabras foro*.

### **¿Existen diferentes patrones de comportamiento relacionados con el esfuerzo y la procrastinación entre los alumnos cuando aprenden a través de un LMS en un contexto real?**

Los resultados del algoritmo EM muestra cuatro clusters diferentes (Log Likelihood = -6,82178). Seguidamente, se aplicó el algoritmo k-means, seleccionando 4 clusters a obtener. El valor de los centroides obtenidos para los 4 clusters generados por el EM y el k-means se muestra en la tabla 5.

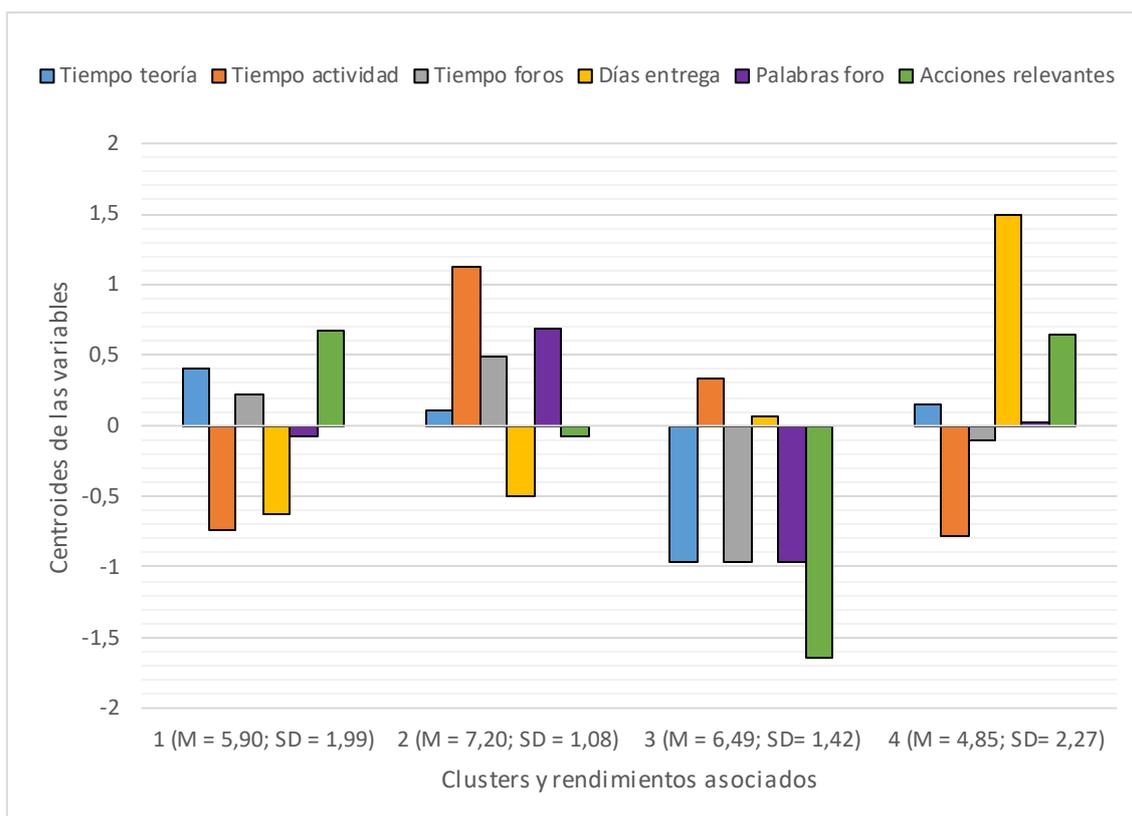
El tercer y último paso, asegurarse de que el número de clusters es correcto, se llevó a cabo con la implementación del Método del Codo. Se inicializó el algoritmo k-means de nuevo, con los valores  $k = 2$ ,  $k = 3$ ,  $k = 4$ ,  $k = 5$  y  $k = 6$ , y se representó gráficamente la suma de errores al cuadrado en función de  $k$ , con el fin de contrastar el número óptimo de clusters.

Tras analizar los datos con el algoritmo EM, algoritmo k-means y el Método del Codo,  $k = 4$  resultó ser el número óptimo de clusters para la muestra. En la figura 14, se representan las características de los cuatro grupos. Para describir el comportamiento de los alumnos en cada grupo, se utilizaron los siguientes criterios: considerando  $M = 0$  y  $SD = 1$  el valor de cada variables es, (a) es muy bajo si la puntuación es inferior a -1,00; (b) es bajo si la puntuación está entre -1,00 y -0,50; (c) es medio si la puntuación está entre -0,50 y 0,50; (d) es alto si la puntuación es positiva y está entre 0,50 y 1,00; y es muy alto si la puntuación es superior a 1,00.

	Cluster 1 n=42	Cluster 2 n=41	Cluster 3 n=27	Cluster 4 n=30
<b>Algoritmo EM</b>				
<i>Tiempo actividad</i>	-0,87 ± 0,33	0,99 ± 0,75	0,28 ± 0,66	-0,78 ± 0,36
<i>Días entrega</i>	-0,61 ± 0,63	-0,48 ± 0,43	0,11 ± 0,74	1,54 ± 0,60
<i>Palabras foro</i>	-0,08 ± 0,53	0,46 ± 0,95	-0,83 ± 1,36	0,08 ± 0,66
<i>Tiempo teoría</i>	0,52 ± 0,96	0,06 ± 0,80	-0,96 ± 0,69	0,08 ± 1,02
<i>Tiempo foro</i>	0,14 ± 0,57	0,53 ± 1,00	-1,05 ± 0,42	-0,11 ± 1,11
<i>Acciones relevantes</i>	0,78 ± 0,14	-0,05 ± 0,43	-1,68 ± 0,78	0,60 ± 0,54
<b>Algoritmo k-means</b>				
<i>Tiempo actividad</i>	-0,74 ± 0,44	1,12 ± 0,71	0,33 ± 0,67	-0,78 ± 0,35
<i>Días entrega</i>	-0,63 ± 0,53	-0,50 ± 0,48	0,06 ± 0,72	1,50 ± 0,59
<i>Palabras foro</i>	-0,07 ± 0,53	0,69 ± 1,02	-0,97 ± 1,04	0,02 ± 0,65
<i>Tiempo teoría</i>	0,41 ± 0,93	0,11 ± 0,80	-0,97 ± 0,70	0,15 ± 1,03
<i>Tiempo foro</i>	0,22 ± 0,68	0,49 ± 1,01	-0,96 ± 0,57	-0,11 ± 1,07
<i>Acciones relevantes</i>	0,68 ± 0,30	-0,08 ± 0,42	-1,64 ± 0,79	0,64 ± 0,52

**Tabla 5.** Media y desviación típica de los centroides de las variables en los clusters

Tal y como se muestra en la tabla 5, los clusters obtenidos con el EM y el k-means son extremadamente similares en términos de tendencias y valores numéricos. Además, los diferentes grupos se describen sin tener en cuenta el algoritmo empleado (figura 14).



**Figura 14.** Clusters con la media y desviación típica del rendimiento.

En el Cluster 1 obtenido con el k-means se observa poco tiempo dedicado a la actividad práctica y mucho a la teoría. La variable relacionada con la procrastinación también es baja. No obstante, el valor de *acciones relevantes* es alto.

El Cluster 2 está caracterizado por una cantidad media de acciones en el LMS y tiempo dedicado a la teoría; sin embargo, se observa una alta cantidad de tiempo dedicada a la actividad práctica y a los foros sin un comportamiento procrastinador.

En el Cluster 3 la variable de procrastinación está cerca de la media. El tiempo dedicado a la teoría es bajo y, en cambio, el tiempo dedicado a la actividad práctica es alto, aunque no tanto como en el Cluster 2. La participación en los foros (tiempo y palabras) y el número de acciones relevantes, son especialmente bajos.

Finalmente, en el Cluster 4 los alumnos muestran valores muy altos en la variable relacionada con la procrastinación y un nivel bajo en el tiempo dedicado a la actividad práctica. Además, muestran un número de acciones relevantes significativo y niveles medios en los foros y el tiempo dedicado a la teoría en el LMS.

**¿En qué medida las variables obtenidas de los logs de Moodle para configurar los patrones son igualmente adecuadas para configurar los clusters?**

Los resultados indican que la varianza en el conjunto de las seis variables dependientes (71,5%) se explica por la diferencia entre los cuatro clusters (Wilks' Lambda = 0,023;  $F(18, 371) = 57,39$ ;  $p < 0,001$ ,  $\eta^2_p = 0,715$ ); en consecuencia, los cuatro clusters son bastante diferentes unos de otros según su comportamiento en las seis variables.

Centrándose en la pregunta de investigación, los datos de este análisis sugieren que las seis variables dependientes tomadas de manera individual contribuyen significativamente a la diferenciación entre los cuatro clusters de alumnos, aunque algunas de ellas, lo hacen con mayor fuerza que otras. En particular, tres de las seis variables contribuyen fuertemente a la diferenciación inter-grupo: *acciones relevantes* [ $F(3, 136) = 136,62$ ;  $p < 0,001$ ;  $\eta^2_p = 0,751$ ], *tiempo actividad* [ $F(3, 136) = 99,83$ ;  $p < 0,001$ ;  $\eta^2_p = 0,688$ ] y *días entrega* [ $F(3, 136) = 96,16$ ;  $p < 0,001$ ;  $\eta^2_p = 0,680$ ], mientras que las otras tres contribuyen con menor intensidad: *palabras foro* [ $F(3, 136) = 22,01$ ;  $p < 0,001$ ;  $\eta^2_p = 0,327$ ], *tiempo foro* [ $F(3, 136) = 16,46$ ;  $p < 0,001$ ;  $\eta^2_p = 0,266$ ], y *tiempo teoría* [ $F(3, 136) = 14,506$ ;  $p < 0,001$ ;  $\eta^2_p = 0,242$ ]. Sin embargo, el tamaño del efecto en las seis variables es grande.

Para finalizar, los resultados de múltiples comparaciones mostraron diferencias estadísticamente significativas en todas las comparaciones excepto en los siguientes casos: tiempo actividad, palabras foros, y acciones relevantes (C1 vs C4), días trabajo (C1 vs C2), tiempo foros (C1 vs C2 y C4), y tiempo teoría (C1 vs C2 y C4, y C2 vs C4).

**¿Existe relación entre los patrones de esfuerzo y procrastinación obtenidos de los logs de Moodle con el rendimiento final?**

La tercera pregunta buscaba eximir las posibilidades de que estos patrones, ahora en clusters, estuvieran relacionados con el rendimiento final de los alumnos. Para este propósito, se realizó un análisis ANOVA. Los resultados obtenidos de la ANOVA con el procedimiento univariante empleando *rendimiento final* como la variable dependiente y los diferentes clusters como variables independientes, donde  $F(3, 136) = 33,74$ ;  $p < 0,001$ ;  $\eta^2_p = 0,198$ , indica que hay diferencias estadísticamente significativas entre los cuatro clusters de alumnos según su rendimiento final. Los análisis realizados con la prueba T mostraron las siguientes diferencias estadísticamente significativas: cluster 1 vs

cluster 2 ( $M_{C1} = 5,90$ ;  $M_{C2} = 7,20$ ;  $t(81) = -3,698$ ,  $p < 0,001$ ;  $d = 0,82$ , efecto grande), cluster 1 vs cluster 4 ( $M_{C1} = 5,90$ ;  $M_{C4} = 4,85$ ;  $t(70) = 2,066$ ;  $p < 0,05$ ;  $d = 0,49$ , efecto mediano), cluster 2 vs cluster 3 ( $M_{C2} = 7,20$ ;  $M_{C3} = 6,49$ ;  $t(66) = 2,336$ ;  $p < 0,01$ ;  $d = 0,58$ , efecto mediano), cluster 2 vs cluster 4 ( $M_{C2} = 7,20$ ;  $M_{C4} = 4,85$ ;  $t(69) = 5,785$ ;  $p < 0,001$ ;  $d = 1,39$ , efecto muy grande), and cluster 3 vs cluster 4 ( $M_{C3} = 6,49$ ;  $M_{C4} = 4,85$ ;  $t(55) = 3,217$ ;  $p < 0,001$ ;  $d = 0,87$ , efecto grande). Las diferencias entre Cluster 1 vs Cluster 3 no fueron estadísticamente significativas.

## 4.5 Discusión

Los resultados parecen responder a las preguntas de investigación planteadas en este capítulo. Se han obtenidos cuatro patrones de interacción diferentes en el LMS con diferentes rendimientos en el curso; sin embargo, es particularmente interesante cómo se agrupan en parejas: Clusters 1 y 4 y Clusters 2 y 3. A continuación, se han etiquetado los clusters para facilitar su interpretación y los rendimientos asociados. Las variables que están más relacionadas con el rendimiento final son: *tiempo actividad*, seguida por *días entrega* y *palabras foro*; por lo tanto, se han empleado estos atributos para etiquetar a los clusters:

- Cluster 1: Grupo no orientado a la actividad (no procrastinadores).
- Cluster 2: Grupo orientado a la actividad (enfoque social).
- Cluster 3: Grupo orientado a la actividad (enfoque individual).
- Cluster 4: Grupo no orientado a la tarea (procrastinadores).

La variable *tiempo actividad* parece estar altamente relacionada con el rendimiento; en este sentido, los alumnos en los Clusters 2 y 3 están muy orientados a la actividad y obtienen los mejores rendimientos finales, mientras que los alumnos de los Clusters 1 y 4 no están orientados a la actividad y obtienen rendimientos más bajos. Además, la variable *días entrega* ayuda a distinguir a las parejas de clusters. Los alumnos del Cluster 4 son muy procrastinadores, mientras que los estudiantes del Cluster 1 no procrastinan en absoluto. A su vez, para los clusters orientados a la actividad, puede observarse que los alumnos del Cluster 2 son más procrastinadores que los que forman parte del Cluster 3. Estas diferenciaciones básicas en los comportamientos procrastinadores tienen sentido

con los resultados del rendimiento. Por último, las variables relacionadas con los foros (*palabras foro, tiempo foro*) ayudan a refinar el etiquetado de los clusters, especialmente entre los Clusters 2 y 3. Parece ser que los alumnos del Cluster 2 están más involucrados en los foros, algo que no se reproduce en el Cluster 3. Basándose en esto y asumiendo que los foros se diseñaron para favorecer el aprendizaje colaborativo, se puede afirmar que el primer grupo tiene un enfoque social y el otro tiene un enfoque individual. A partir de esta primera interpretación, se analizarán los clusters en mayor profundidad.

El grupo no orientado a la actividad (no procrastinadores) se caracteriza por dedicar poco tiempo a trabajar en la actividad práctica y una larga cantidad de tiempo en los contenidos teóricos. Además, la variable de procrastinación y las variables relacionadas con los foros son bajas o medias. Sin embargo, el número de acciones relevantes en el LMS es alto. Considerado que su rendimiento es medio-bajo, estos resultados podrían indicar que los estudiantes en este cluster quieren dejar hecho el trabajo tan pronto como sea posible aplicando el menor esfuerzo posible, mostrando un aprendizaje superficial y la posibilidad de emplear estrategias de aprendizaje no adaptativas o desreguladas. Trabajan rápido, pero no eficientemente; realizan demasiada cantidad de acciones para obtener un rendimiento bajo-medio. A primera vista, se podría pensar que estos alumnos pasan la mayoría del tiempo en la teoría, y así sería consistente con su baja puntuación en tiempo dedicado a las actividades. En consecuencia, más que ser “no orientados a la actividad”, estos alumnos podrían estar “orientados a la teoría”. Sin embargo, anteriormente se puntualizó que el tiempo revisando los contenidos teóricos o los foros no sean probablemente tan fiables como el tiempo dedicado a las actividades ya que el experimento se realiza fuera de las horas de docencia y los alumnos podrían estar trabajando en el LMS o no. En contraposición, el tiempo dedicado a las actividades es un indicador muy fiable en este análisis porque usa la opción que proporciona Moodle para limitar el tiempo en cada actividad; además los resultados demostraron que la variable *tiempo actividad* contribuye de manera más fuerte a la diferenciación inter-grupo.

Además, la variable *acciones relevantes* puede ser un indicador de estar realizando interacción importante en el LMS (interaccionar con el contenido teórico, intentar resolver las actividades prácticas, consultar el foro de discusión, etc). Se asume que todas estas acciones podrían indicar que el estudiante está debidamente involucrado en su proceso de aprendizaje. Como ocurre tradicionalmente con el tiempo de estudio, sin embargo, la variable por sí misma es engañosa. Podría parecer que cuanto más tiempo

dedican los alumnos a estudiar, mayor rendimiento deberían obtener, pero no es tan simple; depende más de la calidad del tiempo de estudio (Plant, Ericsson, Hill, y Asberg, 2005). Algo similar podría estar ocurriendo con la variable acciones relevantes; más actividad en el LMS no asegura mejores resultados. Por esta razón, la interpretación de esta variable está necesariamente vinculada a otras variables relevantes en el proceso de aprendizaje. Tal y como muestran los resultados, los alumnos en los dos grupos “orientados a la actividad” muestran una puntuación baja en la variable *acciones relevantes*, pero las más altas en *rendimiento final*. Debido a esto, el uso del cluster y la variable de rendimiento como variable dependiente podría ser una buena solución para interpretar mejor el rol de cada variable. Profundizar más en las actividades de los alumnos es esencial desde el punto de vista del diseño instruccional porque las investigaciones muestran que la efectividad en un LMS depende fuertemente del uso de herramientas adaptativas por parte de los alumnos (Lust et al., 2013a).

Con respecto al grupo “orientado a la actividad (enfoque social)”, es sabido que no hay un camino teóricamente “perfecto” o nivel para cada variable, simplemente las recomendaciones que hace el profesor al inicio del curso pero, a primera vista, estos estudiantes parecen ser los más eficientes. Teniendo en cuenta que la variable *rendimiento final* tiene el valor más alto, se podría describir a estos alumnos como estratégicos, fundamentalmente por las pocas acciones relevantes que necesitan realizar en el LMS para obtener resultados altos. El patrón que siguen las variables de esfuerzo también parece adecuado, con una alta cantidad de tiempo dedicado a las actividades y a los foros (las actividades obligatorias de las unidades), y no emplean excesivo tiempo en los contenidos teóricos. Estos resultados se asemejan a los obtenidos por Lust, Elen, y Clarebout (Lust et al., 2013a), quienes descubrieron que solamente una minoría de los estudiantes regulaban su comportamiento en base a las necesidades del curso, siendo más adaptativos para el aprendizaje. Al mismo tiempo, no procrastinan, trabajando rápido y entregando las actividades pronto, sin afectar esto a las variables relacionadas con el tiempo dedicado a trabajar.

El otro grupo “orientado a la actividad”, con un enfoque individual, es similar al anterior en términos de rendimiento, pero no en el resto de variables; aunque su comparación es tanto interesante, como desafiante. El rendimiento de este grupo es ligeramente menor que el grupo de enfoque social, pero a su vez, es alto; podría considerarse medio-alto. La procrastinación y el tiempo de trabajo está cerca de la media;

en contraposición, la participación y el tiempo en los foros es muy baja, la más bajas de los 4 clusteres, aunque tienen un valor suficiente para puntuar. El número de acciones relevantes también tiene el valor más bajo en este cluster. Teniendo en cuenta que el esfuerzo que emplean estos alumnos en el foro es bajo y, aún así, obtienen rendimientos altos, podría discutirse que, en lugar de sentirse atraídos por la tarea y por participar en los foros, como hace el otro grupo “orientado a la actividad”, podrían estar dedicando el tiempo a estudiar los contenidos teóricos.

Sin embargo, los resultados muestran que también tienen la puntuación más baja de los 4 clusters en la variable que mide el tiempo dedicado a la teoría. La meta del curso, sin embargo, no se basaba simplemente en la adquisición de conocimiento declarativo si no también de conocimiento procedimental y condicional. En esta línea, el énfasis del docente y las directrices proporcionadas para superar el curso, estaban orientadas a las actividades prácticas y al aprendizaje colaborativo a través de los foros. Es necesario tener esto en cuenta porque, de otro modo, no se podrían hacer suposiciones sobre el comportamiento estratégico de los alumnos en el grupo “orientado a la actividad (énfasis social)” y compararlo con este grupo parcialmente estratégico. La meta que debía orientar el aprendizaje en este curso era poner estrategias en práctica, no que los alumnos aprendieran las estrategias.

En este punto, se podría hacer referencia una vez más a la calidad del tiempo de estudio. Parece ser que los alumnos de este cluster no destacan por pasar mucho tiempo aprendiendo, pero sacan mucho partido del poco tiempo que estudian y obtienen buenos resultados en términos de rendimiento. En este análisis no se proporcionan datos específicos sobre esta situación, sin embargo, la calidad del proceso de aprendizaje de estos alumnos probablemente sea mala y probablemente también sean estratégicamente menos eficientes que el otro grupo, a pesar de que su rendimiento sea aceptable. Así pues, un entorno virtual de aprendizaje basado en recomendaciones en lugar de adaptación, podría ser suficiente para este tipo de patrón de interacción.

Por último, el grupo “no orientado a la tarea (procrastinadores)” se caracteriza por las puntuaciones más bajas, lo cual no es sorprendente tras analizar su patrón de comportamiento en el LMS. Su característica más destacable es que son alumnos extremadamente procrastinadores con valores bajos en las variables relacionadas con el tiempo dedicado a trabajar en las actividades. Además, emplean un número significativo

de acciones relevantes, una buena cantidad de tiempo en la teoría y escriben bastante en el foro, sin saber cómo beneficiarse de esta situación. Esto denota una falta de estrategias de aprendizaje y probablemente un acercamiento desadaptativo al aprendizaje. Tal y como se muestra en Greene, Mos y Azevedo (2011), las habilidades SRL son esenciales para obtener un aprendizaje efectivo en contextos reales y especialmente en sistemas software. Por tanto, si la falta de eficiencia observada en este cluster efectivamente proviene de los desafíos a los que los alumnos se enfrentan en los LMSs, se podría optimizar su rendimiento a través de un andamiaje de soporte, específico y efectivo para tomar ventaja del tiempo que dedican trabajando a través de los procesos SRL (Devolder, van Braak, y Tondeur, 2012); en este sentido, los sistemas hipertexto adaptativos educativos, podrían ser una buena solución.

Estos resultados son interesantes en dos sentidos. Por una parte, podrían ayudar a un docente a entender mejor las características de aprendizaje de los alumnos y su interacción en el LMS, además de ayudar a los estudiantes en riesgo, por ejemplo, los que forman parte de los grupos no orientados a la actividad o a los procrastinadores. Podría pensarse de estos alumnos como un reflejo de un comportamiento de aprendizaje desregulado (Azevedo y Feyzi-Behnagh, 2011) y que apoyan la abundante evidencia empírica de que los estudiantes normalmente no modifican adaptativamente su comportamiento cuando aprenden en este tipo de sistemas. Por otra parte, la información obtenida de los grupos “orientados a la actividad” se relaciona con el diseño de sistemas recomendadores (Alstete y Beutell, 2004; Hrastinski, 2006); teniendo un rendimiento similar, el comportamiento en el LMS demuestra diferentes patrones de comportamiento que podrían reconducirse mediante un sistema recomendador. Emplear diferentes tipos de adaptación, a un nivel de granularidad alto, podría ser útil para asegurar el éxito académico y la calidad de los procesos de aprendizaje. En este sentido sería necesario proporcionar indicaciones de cómo un LMS puede adaptarse a determinados estudiantes (Lust et al., 2012), pero para este propósito, es necesario tener el conocimiento obtenido en este análisis.



# Capítulo 5

## Variables de procrastinación en LMSs

En el anterior capítulo, se descubrieron y discutieron diferentes patrones de comportamiento entre los estudiantes que participan en un LMS. Una de las variables que configuraba esos patrones, se relacionaba con la procrastinación. Así pues, en este capítulo se analizará los indicadores de procrastinación de los alumnos en el LMS y su relación con el rendimiento final. Además, se analizará si estos comportamientos son consistentes en diferentes años académicos.

### 5.1 Introducción

La investigación sobre el aprendizaje autorregulado comprende un amplio campo de conocimiento. Nos ha mostrado que alumnos de todas las edades tienen dificultades a la hora de aplicar habilidades claves de autorregulación cognitivas y metacognitivas durante el aprendizaje en entornos de aprendizaje abiertos (Azevedo, 2015), como es el caso de los LMSs. Las plataformas de aprendizaje han proporcionado nuevas oportunidades para propagar la educación (Comisión Europea, 2014) pero también generan múltiples desafíos para los alumnos. Decidir qué, cuándo, cómo y durante cuánto tiempo aprender, es decir, autorregularse, tiene mayor relevancia en este contexto (Azevedo, Witherspoon, Chauncey, Burkett, y Fike, 2009; Jacobson, 2008; Klingsieck, Fries, Horz, y Hofer, 2012; Lajoie y Azevedo, 2006; Michinov et al., 2011; Sánchez-Santillán, Paule-Ruiz, Cerezo, y Álvarez-García, 2016; Winters, Greene, y Costich, 2008; You, 2015). A lo largo de este capítulo, se estudiara una pequeña, pero determinante, parte de la autorregulación: la procrastinación, intentando descubrir su relación con el bajo rendimiento de los alumnos en los LMSs.

Existen numerosos estudios que hablan sobre la importancia de la gestión del tiempo y del aprendizaje, refiriéndose no sólo a la cantidad, si no también a la calidad del tiempo que dedican los alumnos a estudiar (Balkis, 2011). Muchos de estos estudios se centran en la procrastinación, entendida como la “tendencia a posponer una actividad, que

depende de uno mismo, hasta el último minuto, llegando incluso a no realizarla” (Gafni y Geri, 2010). La procrastinación es uno de los lapsos más extendidos en la gestión del tiempo, siendo un comportamiento común en los alumnos de todas las etapas educativas (Karatas, 2015; Katz, Eilot, y Nevo, 2014; Rabin, Fogel, y Nutter-Upham, 2011; Romero, 2013; Terry, 2002). Por ejemplo, Sánchez (2010) halló la presencia de este tipo de comportamientos en el 80% de los estudiantes universitarios, siendo crónico en el 20% de ellos. Por tanto, el comportamiento procrastinador, aunque sea una práctica en las sociedades occidentales modernas, debe ser investigado en mayor profundidad (Levy y Ramim, 2012).

El efecto negativo de la procrastinación en el aprendizaje y el rendimiento se ha observado y estudiado en la enseñanza tradicional, sin embargo, hay una falta de estudios relacionados con plataformas de aprendizaje. Esta situación es especialmente delicada, pues la procrastinación parece tener mayor influencia en el aprendizaje a distancia (Tuckman, 2005). Además, parece ser que los alumnos que demuestran tener habilidades autorregulatorias, tienen mayor oportunidad de éxito en los sistemas software de aprendizaje (Winters et al., 2008).

Por otra parte, los LMSs presentan diferencias importantes, en relación a lo que supone el aprendizaje tradicional, que deberían tenerse en cuenta, pero también presentan ventajas para detectar y solucionar estos desafíos. Los LMSs recolectan una gran cantidad de datos sobre la interacción de los alumnos con la plataforma. Estos datos pueden proporcionar información importante para mejorar el proceso de aprendizaje tanto a los investigadores como a los docentes (Paule-Ruiz, Riestra-Gonzalez, Sánchez-Santillan, y Pérez-Pérez, 2015).

Para analizar este tipo de datos, la Minería de Datos Educativa (Romero et al., 2013), pone a disposición diferentes técnicas, que se han empleado para: entender mejor cómo funcionan los procesos de aprendizaje, generar sistemas recomendadores que proporcionen feedback a los alumnos, profesores o docentes, prevenir el fracaso académico, etc. En resumen, se han utilizado para ayudar a los alumnos a superar las dificultades que surgen cuando se aprende en sistemas de aprendizaje e-Learning (Azevedo et al., 2012).

Las reglas de asociación, es una de las técnicas más empleadas en la Minería de Datos (Luna et al., 2015), y han sido ampliamente utilizadas en el campo de la EDM, como

puede observarse en la sección *Minería de Datos y la interacción en los LMSs*. Basándose en estos trabajos previos, en los siguientes apartados se realizará este tipo de análisis sobre los registros obtenidos en cursos de un LMS, para descubrir patrones de comportamiento relacionados con la procrastinación. Estos patrones podrían ser utilizados a la hora de predecir la evolución de los procesos de aprendizaje y su resultado.

## 5.2 Objetivos del estudio

A lo largo de las próximas secciones del capítulo, se extraen múltiples reglas de asociación con clase, basadas en la interacción de los alumnos con un LMS, relacionando la interacción con el rendimiento final obtenido. Los datos se han obtenido de un curso cuya duración es de 11 semanas, y forma parte de una asignatura obligatoria del grado de Psicología de una universidad en el Norte de España. El objetivo principal de este estudio es contribuir al conocimiento sobre cómo la procrastinación en LMSs se relaciona con el rendimiento de los alumnos. Por tanto, se plantean las siguientes preguntas de investigación:

1. ¿Tiene el comportamiento procrastinador un valor predictivo sobre el rendimiento de los alumnos interactuando en un LMS?
2. ¿Pueden utilizarse las hipotéticas reglas de asociación en muestras de años posteriores para predecir el rendimiento de los alumnos en un LMS?
3. ¿Está relacionado el comportamiento procrastinador inversamente con el rendimiento de los alumnos en un LMS?

Con el fin de responder a estas preguntas, se han empleado dos fuentes de información generadas tras finalizar los estudiantes la interacción con el curso del LMS. La primera fuente son los logs proporcionados por el propio LMS, un Moodle en su versión 2.0. Moodle proporciona de base herramientas para que cualquier docente descargar los registros de interacción de los alumnos. Y, la segunda fuente, es el rendimiento final obtenido en el curso por los alumnos.

Los siguientes apartados están organizados de la siguiente manera. Tras establecer las preguntas de investigación, se describe la metodología dividida en tres fases. En la primera fase, se describen los participantes y el procedimiento, así como el proceso de extracción de variables. En la segunda fase, se realiza un análisis basado en reglas de

asociación con clase en dos años académicos consecutivos para predecir, separadamente, el rendimiento de los alumnos. En la tercera y última fase, se filtran las reglas obtenidas en cada año académico, obteniendo como resultado las reglas comunes a los dos años académicos.

## **5.3 Metodología**

### **5.3.1 Participantes y procedimiento**

El presente estudio, se ha basado en una muestra total de 140 alumnos matriculados en el grado de Psicología en una universidad en el Norte de España durante dos años consecutivos ( $N_1 = 67$ ;  $N_2 = 73$ ). Las variables empleadas, han sido obtenidas a través de los logs de una plataforma Moodle 2.0, basándose en variables obtenidas en estudios previos (Cerezo, Sánchez-Santillán, Paule-Ruiz, y Núñez, 2016; Hung y Zhang, 2008; J. H. Kim et al., 2014; Lust et al., 2012, 2013a; Macfadyen y Dawson, 2010; Murray et al., 2012). Teniendo en cuenta estos trabajos, se han seleccionado las variables que configuran la interacción de los alumnos en el curso implementado en el LMS: las variables relacionadas con el esfuerzo y el tiempo dedicado al trabajo (necesarias para asegurarse de que los alumnos realizan el mínimo de tareas obligatorias), y las variables relacionadas con el comportamiento procrastinador.

El programa de entrenamiento a completar en el LMS fue el denominado eTraining for Autonomous Learning – eTRAL (Cerezo et al., 2010; Núñez et al., 2011) implementado como parte del currículo de una asignatura y completado totalmente fuera de los horarios de docencia. El programa está dividido en 11 bloques, donde a los alumnos se les da acceso a un nuevo bloque cada semana y teniendo quince días para completarlo. Por cada bloque, además de poder debatir en el foro y consultar un contenido teórico, los alumnos tienen que completar una actividad práctica y expresar su opinión en el foro (de forma independiente al debate). Para dar por superado el programa eTRAL, los alumnos debían completar el 80% de los bloques con el fin de obtener un punto extra en el rendimiento final de la asignatura. Puede consultarse más información sobre el programa en Cerezo, Bernardo, Esteban, Sánchez, y Tuero (2015).

### 5.3.2 El proceso de extracción de variables

Tras finalizar la experiencia con eTRAL, se analizó el fichero de generado por la interacción de los estudiantes en el LMS. El fichero de log analizado, es un fichero de texto plano, cuyos campos están separados por tabulaciones. Los campos que proporciona el fichero son: la fecha del evento, el usuario que la realiza, la acción que se realiza y sobre qué elemento se realiza la acción. Para calcular el tiempo que el alumno dedica a cada evento, se resta la fecha de una acción a la fecha de la acción anterior. Tras calcular los tiempos en minutos de las acciones, se filtraron del fichero de log aquellas acciones que estaban relacionadas con las variables empleadas, descartando el resto. Moodle en su versión 2.0 almacena automáticamente 76 acciones (en el *Diagramas del prototipo implementado* están disponibles todas las acciones que almacena Moodle). En este estudio se han seleccionado 11 acciones de Moodle basándose recomendadas en estudios previos (J. H. Kim et al., 2014; Lust, Elen, y Clarebout, 2013b) y el rendimiento final obtenido por los alumnos en el curso. Para convertir estas acciones en variables, se siguen diversos métodos en función de la complejidad de la variable. En algunos casos, se obtienen directamente del log, en otros casos, es necesario realizar operaciones aritméticas para calcularlas. Por ejemplo, la variable *días escribe* se calcula restando la fecha en la que un alumno escribe su opinión en el foro del bloque y la fecha de apertura del bloque, y por tanto, del foro.

Las variables extraídas, disponibles en la tabla 6, se han organizado en dos grupos diferentes teniendo en cuenta el valor que tienen en un nivel superior de granularidad: Variables relacionadas con el esfuerzo y el tiempo de trabajo y las variables relacionadas con la procrastinación.

Las *variables relacionadas con el esfuerzo y el tiempo de trabajo* que han sido seleccionadas para el estudio son: *tiempo teoría*, *tiempo actividad*, *tiempo foro*, y *acciones relevantes*; puesto que son indicadores indirectos del esfuerzo realizado por el alumno en el LMS.

Nombre	Descripción	Información adicional
<b>Variables de esfuerzo y tiempo de trabajo</b>		
<i>Tiempo actividad</i>	Tiempo total dedicado a las actividades prácticas	Los alumnos tienen 15 días para completar la actividad
<i>Tiempo teoría</i>	Tiempo total dedicado a los contenidos teóricos	Los alumnos tienen 15 días para acceder a los contenidos teóricos
<i>Tiempo foro</i>	Tiempo total dedicado al foro	Los alumnos tienen 15 días para acceder y participar en los foros
<i>Acciones relevantes</i>	Número de entradas en el log relacionadas con las acciones seleccionadas.	Acciones tales como: inicio de sesión, cierre de sesión, ver el calendario, etc, se descartaron.
<b>Variables de procrastinación</b>		
<i>Días teoría</i>	Los días que pasan desde que se abre el bloque hasta que el alumno consulta el contenido por primera vez	Los alumnos tienen 15 días para consultar el contenido teórico.
<i>Días actividad</i>	Los días que pasan desde que se abre el bloque hasta que el alumno lee el enunciado por primera vez	Los alumnos tienen 15 días para consultar el enunciado de la actividad.
<i>Días entrega</i>	Los días que pasan desde que se abre el bloque hasta que el alumno envía la actividad práctica.	Los alumnos tienen 15 días para entregar las tareas.
<i>Días foro</i>	Los días que pasan desde que se abre el bloque hasta que el alumno accede al foro por primera vez.	Los alumnos tienen 15 días para acceder al foro.
<i>Días escribe</i>	Los días que pasan desde que se abre el bloque hasta que el alumno escribe su primera opinión en el foro.	Los alumnos tienen 15 días para dar su opinión en el foro.

**Tabla 6.** Categorización y descripción de las variables seleccionadas.

Las variables relacionadas con la procrastinación que han sido seleccionadas para el estudio se basan tanto en el tiempo que tardan los alumnos en acceder a los diferentes tipos de contenidos: la actividad (*días actividad*), el foro (*días foro*) y el contenido teórico

(*días teoría*), como en el tiempo que tardan en realizar las actividades obligatorias: la actividad (*días entrega*) y dar su opinión (*días escribe*). La razón para seleccionar estas variables es aproximar la procrastinación observando el comportamiento de los alumnos en el LMS antes de que finalice el plazo de entrega, y no sólo considerando si entregan o no entregan.

En total, se han seleccionado 9 variables de interacción por parte de los estudiantes en el LMS además del *rendimiento final* obtenido por los estudiantes, como décima variable. Nótese que el rendimiento final no es simplemente la nota obtenida por completar el programa eTRAL en el LMS (el cual tiene un valor de 1 punto sobre 10 sobre el rendimiento final), contempla también la nota obtenida en el examen final de la asignatura. El método de extracción de las variables anteriores, está descrito en la tabla 7.

<b>Variable</b>	<b>Método de extracción</b>
<i>Tiempo actividad</i>	Suma de los tiempos (minutos) sobre la actividad en las acciones: quiz view, quiz attempt, quiz continue attempt, quiz close attempt.
<i>Tiempo teoría</i>	Suma de los tiempos (minutos) sobre el recurso en las acciones: resource view.
<i>Tiempo foros</i>	Suma de los tiempos (minutos) sobre el foro en las acciones: forum view, forum view discussion, forum add discussion, forum add reply, update post y forum add post.
<i>Acciones relevantes</i>	Contador de las acciones contempladas en las variables anteriores.
<i>Días teoría</i>	La diferencia (en días) entre la fecha del primer resource view y la fecha de apertura del bloque.
<i>Días actividad</i>	La diferencia (en días) entre la fecha del primer quiz view y la fecha de apertura del bloque.
<i>Días entrega</i>	La diferencia (en días) entre la fecha del primer quiz close attempt y la fecha de apertura del bloque.
<i>Días foro</i>	La diferencia (en días) entre la fecha del primer forum view discussion y la fecha de apertura del bloque.
<i>Días escribe</i>	La diferencia (en días) entre la fecha del primer forum add reply y la fecha de apertura del bloque.

**Tabla 7.** Proceso de extracción de las variables empleadas.

### 5.3.3 Análisis de datos

Se han aplicado reglas de asociación con clase – Class Association Rules (CAR) a los conjuntos de datos. Las reglas CAR son una variedad de las reglas de asociación que permiten identificar las relaciones entre combinaciones de variables y una clase predefinida antes de ejecutar el algoritmo. Además, las reglas de asociación están definidas por una relación condicional (IF-THEN) entre las variables a analizar (precedente), concatenadas con el operador lógico AND, y la variable de clase (consecuente) (Romero et al., 2010). En el análisis se ha empleado el algoritmo Predictive Apriori (Scheffer, 2001) para obtener reglas cuya variable de clase, o consecuente, sea el rendimiento. Se ha establecido el mínimo de precisión para dar validez a una regla en 0,80. El empleo del algoritmo Predictive Apriori en detrimento del algoritmo Apriori, es debido a que en términos generales, funciona mejor (E. García et al., 2011).

Variable	Método de discretización	Valores discretizados
<i>Tiempo actividad</i>	Equal-width	Bajo, Medio, Alto
<i>Tiempo teoría</i>	Equal-width	Bajo, Medio, Alto
<i>Tiempo foros</i>	Equal-width	Bajo, Medio, Alto
<i>Acciones relevantes</i>	Equal-width	Bajo, Medio, Alto
<i>Días teoría</i>	Equal-width	Pronto, Normal, Tarde
<i>Días actividad</i>	Equal-width	Pronto, Normal, Tarde
<i>Días entrega</i>	Equal-width	Pronto, Normal, Tarde
<i>Días foro</i>	Equal-width	Pronto, Normal, Tarde
<i>Días escribe</i>	Equal-width	Pronto, Normal, Tarde
<i>Rendimiento final</i>	Manual	Bajo, Medio, Alto

**Tabla 8.** Método y valores de la discretización de las variables.

Para obtener las reglas de asociación con clase, se ha utilizado el software Weka (Hall et al., 2009). Para iniciar el algoritmo, Weka necesita que las variables estén discretizadas. La tabla 8 muestra cómo se han discretizado las variables con el método “equal-width”, ya empleado en trabajos previos (Paule-Ruiz et al., 2015; García et al., 2011). Sin embargo, la variable *rendimiento final* ha sido discretizada de forma manual,

estableciendo: un rendimiento “bajo” si es inferior a 5, “medio” si está entre 5 y 7, y alto si es superior o igual a 7.

Por último, la mayoría de los casos, los algoritmos de reglas de asociación generan un volumen muy grande de reglas, dificultando su interpretación y validación, por parte de los investigadores (Kotsiantis y Kanellopoulos, 2006). Puesto que una de las preguntas de investigación está relacionada con el valor predictivo de las reglas en cursos posteriores, y se emplean dos conjuntos de datos de años consecutivos, se han seleccionado exclusivamente las reglas que se repiten en ambos conjuntos de datos. Con este procedimiento, se obtienen reglas que son consistentes en los diferentes conjuntos de datos y los diferentes años académicos.

## **5.4 Resultados**

### **5.4.1 Presencia de las variables en las reglas obtenidas**

Los resultados obtenidos por el algoritmo Predictive Apriori, proporcionaron 49 reglas en el primer conjunto de datos, y 62 reglas en el segundo conjunto de datos, en ambos casos, la precisión ha sido superior a 0,94, obteniendo un total de 111 reglas. El número de reglas obtenido según las variables que forman parte del antecedente y los valores del consecuente, puede observarse en la tabla 9. La aparición de las variables en las reglas, para cada uno de los conjuntos de datos, puede observarse en la figura 15.

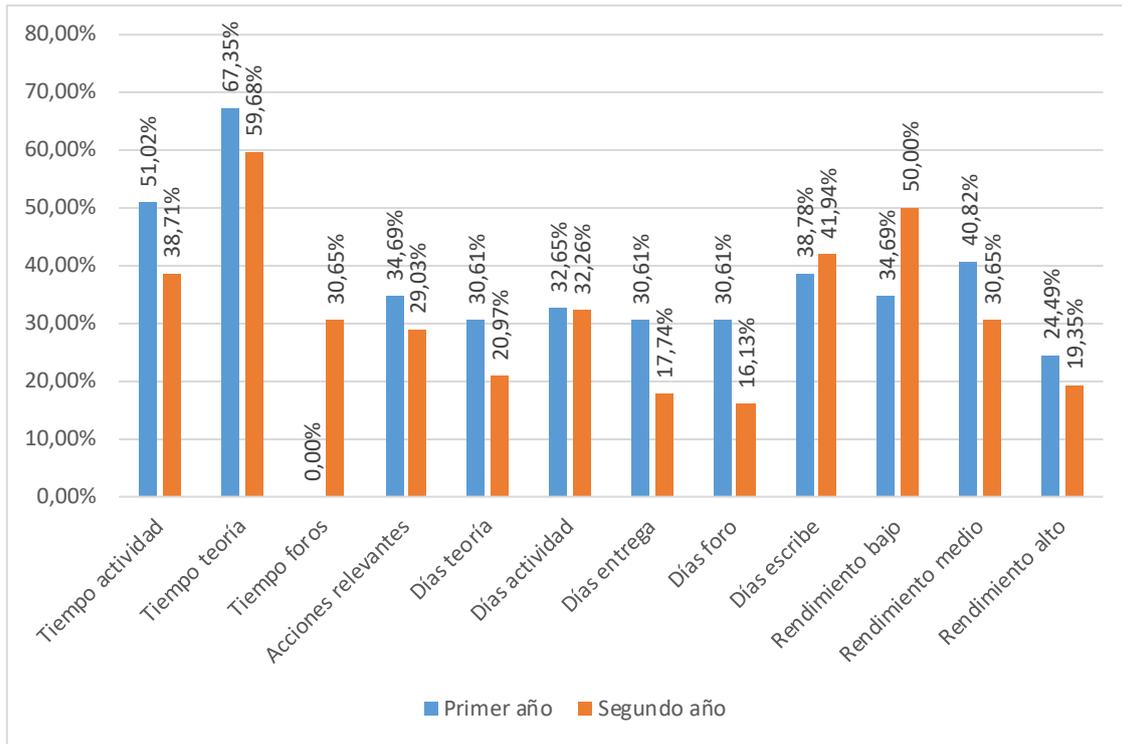


Figura 15. Aparición de las variables en los conjuntos de datos

Variable	Primer año	Segundo año	Ambos
<b>Ante de cente</b>			
<i>Tiempo actividad</i>	25	24	49
<i>Tiempo teoría</i>	33	37	70
<i>Tiempo foros</i>	0	19	19
<i>Acciones relevantes</i>	17	18	35
<i>Días teoría</i>	15	13	28
<i>Días actividad</i>	16	20	36
<i>Días entrega</i>	15	11	26
<i>Días foro</i>	15	10	25
<i>Días escribe</i>	19	26	45
<b>Consecuente</b>			
<i>Rendimiento bajo</i>	17	31	48
<i>Rendimiento medio</i>	20	19	39
<i>Rendimiento alto</i>	12	12	24
<b>Total de reglas</b>	49	62	111

Tabla 9. Aparición de las variables en las reglas de asociación

### **¿Tiene el comportamiento procrastinador un valor predictivo sobre el rendimiento de los alumnos interactuando en un LMS?**

El algoritmo Predictive Apriori ha encontrado 49 reglas en el primer curso académico y 62 reglas en el segundo curso académico, sumando un total de 111 reglas. Todas las variables relacionadas con el comportamiento procrastinador están presentes en ambos conjuntos de datos. El orden de las variables según su nivel de aparición, es el siguiente: *días escribe* (38,78% - 41,94%), *días actividad* (32,65% - 32,26%), *días teoría* (30,61% - 20,97%), *días entrega* (30,61% - 17,74%), *días foro* (30,61% - 16,13%). Las variables *días teoría*, *días entrega* y *días foro*, tienen el mismo nivel de aparición en el primer curso (30,61%), sin embargo, en el segundo curso, decremantan su aparición, algo que también sucede con la variable *días actividad*. La única variable que cuya aparición es superior en el segundo curso académico, es *días escribe* (38,78% vs 41,94%).

Por otra parte, en el primer curso, las variables de esfuerzo y tiempo de estudio, tienen mayor presencia que las variables de procrastinación, excepto *tiempo foro*, cuya presencia es nula y, siendo la única excepción, *acciones relevantes*, cuya presencia es inferior a *días escribe* (34,69% vs 38,78%). Sin embargo, en el segundo año, *días escribe* se sitúa como la segunda variable con mayor presencia, por detrás de *tiempo teoría* (59,68% vs 41,94%) y superando a *tiempo actividad* (41,94% vs 38,71%).

En cuanto al consecuente, es decir, al *rendimiento final*, se observa que la mayoría de las reglas obtenidas, están relacionadas con los rendimientos bajo (34,69% - 50%) y medio (40,82% - 30,65%), siendo en el primer curso superior las reglas de rendimiento medio, y en el segundo curso las de rendimiento bajo. Las reglas de rendimiento alto, son las que menor presencia tienen (24,49% - 19,35%).

### **¿Pueden utilizarse las hipotéticas reglas de asociación en muestras de años posteriores para predecir el rendimiento de los alumnos en un LMS?**

Tras unir todas las reglas obtenidas (N = 111) y filtrarlas mediante un algoritmo simple, se han obtenido las reglas que están presentes en los dos conjuntos de datos. Se considera que una regla está presente en ambos conjuntos, si tienen el mismo precedente (mismas variables y valores, independientemente del orden) y el mismo consecuente (mismo valor de rendimiento). Si una regla cumple las condiciones anteriores pero existe una regla, con una precisión superior a 0,80, que tenga también el mismo precedente pero

diferente consecuente, la regla se descarta automáticamente. El algoritmo ha encontrado tres reglas (figura 16) que están presentes en ambos conjuntos de datos.

1. **días teoría=Normal** y **días actividad=Tarde** →  
**rendimiento=Bajo** (Acc = 0,972)
2. **tiempo teoría=Bajo** y **días teoría=Tarde** and **días foro=Normal** →  
**rendimiento=Bajo** (Acc. = 0,943)
3. **tiempo actividad=Medio** y **días teoría=Pronto** y **días actividad=Normal** →  
**rendimiento=Alto** (Acc. = 0,943)

**Figura 16.** Reglas de asociación presentes en los dos conjuntos de datos

Las tres reglas obtenidas tienen una precisión superior a 0,80, elevando el mínimo a 0,943 obtenido por las reglas 2 y 3 y 0,972 obtenido por la regla 1. Las tres reglas predicen el rendimiento de los alumnos para dos valores, rendimiento alto (regla 3) y rendimiento bajo (reglas 2 y 1). En las tres reglas aparecen variables de procrastinación, destacando la primera regla que está formada exclusivamente por variables de este tipo. En la regla 2 hay mayoría de *variables de procrastinación* (2) que de *variables de esfuerzo y tiempo de estudio* (1).

**¿Está relacionado el comportamiento procrastinador inversamente con el rendimiento de los alumnos en un LMS?**

La regla 1 muestra que si el acceso al contenido teórico se realiza en un tiempo medio y el acceso a la actividad se realiza tarde, entonces el rendimiento es bajo. La regla 2 muestra que si el tiempo medio dedicado al contenido teórico es bajo, si se accede tarde al contenido teórico y, el acceso al foro se realiza en un tiempo medio, el rendimiento es bajo. La regla 3 muestra que si el tiempo dedicado a la actividad es medio, se accede pronto al contenido teórico y el acceso a la tarea se realiza en un tiempo medio, el rendimiento obtenido es alto.

## 5.5 Discusión

A primera vista, y según los resultados, puede observarse que dos de las tres variables presentes en los antecedentes están relacionadas con el comportamiento procrastinador en todas las reglas. Además, en términos generales, las reglas obtenidas muestran que las variables de procrastinación con valores altos presentes en las reglas, implican un rendimiento bajo, y que, una buena gestión del tiempo implica un mejor rendimiento. La presencia de las variables en las 111 reglas también es relevante. Atendiendo de nuevo la figura 15, se observa que tres de las cinco variables con mayor aparición en las reglas, pertenecen al comportamiento procrastinador en el LMS.

En particular, si analizamos la regla 1, puede verse que, cuando un alumno accede al contenido teórico en un tiempo medio pero tarda en realizar la actividad práctica, el rendimiento es bajo. Examinando la regla 2, se observa que si un alumno accede tarde, y le dedica poco tiempo a la teoría, a pesar de que acceda al foro con un tiempo medio, su rendimiento será bajo. Tiene sentido que, cuando un alumno comienza a trabajar tarde en un contenido, el tiempo que le puede dedicar es menor y, en consecuencia, su rendimiento será peor que otros alumnos. Interpretando estos resultados en términos de procrastinación, vienen a ser más pesimistas, pero en la misma línea, que los obtenidos por Paule-Ruiz et al. (2015), cuyo estudio muestra que los alumnos que procrastinan, obtienen peores resultados. También están en consonancia con los hallados por Michinov et al., (2011), en los que se determina que la procrastinación en entornos de aprendizaje online está influenciado por el nivel de participación de los alumnos en el foro. Profundizando más, esta regla podría indicar que, aunque los alumnos comiencen a trabajar con un margen de tiempo medio, están en riesgo de convertirse en procrastinadores y que esto acabe afectando a su rendimiento. Esta interpretación podría ser muy valiosa teniendo en cuenta que los estudiantes que posponen y entregan las actividades a última hora, muestran peor retención a largo plazo y, también, peor rendimiento (Asarta y Schmidt, 2013; Tuckman, 2005). Una aplicación clave de estos resultados se relaciona directamente con la personalización de las plataformas e-Learning, como puede ser el caso del empleo de diferentes tipos de mensajes, en tiempo y forma, para distintos conjuntos de alumnos (Lehmann, Hähnlein, y Ifenthaler, 2014) y construir sistemas recomendadores basados también en grupos (Kardan, Saryazdi, y Mirashk, 2012). Poniendo en conjunto el conocimiento aportado por este trabajo y los

previamente citados, este estudio podría contribuir a generar un modelo de usuario válido para los sistemas hipermedia adaptativos (Brusilovsky, 2001; Cerezo et al., 2016).

Con respecto a la regla 3, muestra cómo un proceso de aprendizaje más organizado, dentro de la media, puede dirigir al alumno al éxito académico. Cuando el alumno accede al contenido teórico temprano, consulta lo que tiene que hacer en la actividad en un tiempo medio, y le dedica un tiempo medio a completarla, obtiene un rendimiento alto. Cabe destacar que esta es la única regla que incluye un valor “temprano” de procrastinación en el antecedente y, además, la única que incluye un valor de rendimiento alto en el consecuente. La información proporcionada por esta regla, coinciden con las conclusiones del metanálisis realizado por Kim y Seo (2015), en el que se detectó una correlación negativa entre las variables de procrastinación con el rendimiento del alumno.

En este punto, las reglas de asociación halladas, permiten responder a las dos primeras preguntas de investigación, apoyando que las variables de procrastinación pueden utilizarse para predecir el rendimiento de los alumnos (1ª pregunta de investigación) y que las variables de procrastinación están inversamente relacionadas con el rendimiento del alumno (2ª pregunta de investigación).

La tercera pregunta de investigación, estaba relacionada con el valor predictivo de estas reglas en años sucesivos, parece ser que está contestada por la propia metodología. Aunque se obtuvieran 111 reglas entre los dos años académicos, las reglas que se han discutido son las únicas que están presentes en ambos años, con el mismo precedente en términos de variables de esfuerzo y variables de procrastinación, y el mismo consecuente en términos de rendimiento. Parece ser que estos indicadores son estables a lo largo del tiempo (diferentes cursos) e independientes (diferentes muestras) por lo que podrían usarse las reglas en los próximos cursos académicos para guiar a los estudiantes en el proceso de aprendizaje. Se han encontrado implicaciones prácticas en los estudios de Sekhavatian y Mahdavi (2011), Mosharral y Tashiyareh (2012), y Muruganathan y ShivaKumar (2016), en los que se emplearon este tipo de indicadores como base de un sistema recomendador de e-Learning en años posteriores.

# Capítulo 6

## Conclusiones

El objetivo principal de esta tesis era descubrir variables de comportamiento de los alumnos en los LMSs para que pudieran ser empleadas en un modelo de interacción y adaptación con el fin de mejorar el proceso enseñanza-aprendizaje. A continuación, se discute el grado de completitud del objetivo, partiendo desde la base (el modelo teórico que soporta estas variables) hasta las variables y patrones de comportamiento descubiertos.

Se ha presentado un modelo teórico de interacción-adaptación en el que se describen tanto la interacción de los agentes (docente, alumno y LMS), como los procesos y la naturaleza de las variables que dan soporte a la adaptación. Uno de los pilares fundamentales de este modelo, es el empleo de un modelo de usuario flexible, pudiendo aplicar las mismas variables en ámbitos reducidos del mismo contexto pero con diferentes valores. El objetivo fundamental de este modelo era dar soporte a nuevas variables de comportamiento, así como mejorar el proceso de enseñanza-aprendizaje. Se ha implementado un prototipo que soporta este tipo de variables, y se ha presentado un posible caso de uso basado en variables motivacionales en el que los alumnos desplegarían procesos autorregulatorios claves durante su aprendizaje (Azevedo et al., 2011; Roger Azevedo y Witherspoon, 2009; Quintana et al., 2005), cumpliendo esta parte del objetivo. Sin embargo, no se puede afirmar que el modelo mejore el proceso E-A hasta que se pruebe y se analicen empíricamente los resultados. Por otra parte, la arquitectura presentada es válida para LMSs, tal y como prueba el prototipo en Moodle, pero los LMSs son simplemente uno de los componentes que forman el ecosistema del aprendizaje (Francisco José García-Peñalvo y Pardo, 2015; Uden, Wangsa, y Damiani, 2007), por lo que no es una arquitectura genérica para e-Learning.

Con el fin de obtener nuevas variables y poder complementar el modelo, basándose más en la interacción que realiza el alumno sobre el LMS que en la percepción que tiene sobre sí mismo en el momento que rellena un autoinforme, se han obtenido cuatro clusters

según los patrones de comportamiento de los alumnos en los LMSs. El etiquetado de los grupos ha sido el siguiente: grupo no orientado a la actividad (no procrastinadores), grupo no orientado a la actividad (procrastinadores), grupo orientado a la actividad (enfoque individual) y grupo orientado a la actividad (enfoque social). Estos patrones están directamente relacionados con el rendimiento final obtenido por los alumnos. Se han hallado diferencias significativas entre los grupos: “no orientado a la actividad (no procrastinadores) y “orientado a la actividad (enfoque social)”, “no orientado a la actividad (no procrastinadores)” y “no orientados a la tarea (procrastinadores)”, “orientado a la actividad (enfoque social)” y “orientado a la actividad (enfoque individual)”, “orientado a la actividad (enfoque social)” y “no orientado a la actividad (procrastinadores)”, “orientado a la actividad (enfoque individual)” y “no orientado a la actividad (procrastinadores)”.

Las variables relacionadas tanto con el esfuerzo y el tiempo de trabajo, como con la procrastinación, además de ser relevantes para agrupar a los alumnos, también son esenciales para predecir el rendimiento. El grupo que pasa más tiempo en las actividades (grupos orientados a la actividad), rinden mejor que los que pasan menos tiempo en estas (grupos no orientados a la actividad). Sin embargo, el tiempo de trabajo no debe confundirse con el tiempo que se dedican los alumnos a la teoría o al foro, al menos, en este caso.

El análisis de la variable relacionada con la procrastinación, indica que los alumnos que tardan más en entregar la tarea, son más propensos a obtener un rendimiento bajo. Las diferencias más significativas se dan entre los alumnos que forman los grupos “orientado a la tarea (enfoque social)” y “no orientado a la tarea (procrastinadores)”, en los que, la diferencia de comportamiento de estas variables, expresan una relación inversa con el rendimiento. Estos resultados son coherentes con los patrones de los grupos “orientado a la tarea (enfoque individual)” y “no orientado a la tarea (no procrastinadores), donde la procrastinación se acerca a niveles medios, obteniendo un rendimiento también medio.

Además, se descubrió que no todas las variables obtenidas de los logs de Moodle son adecuadas, o igualmente adecuadas, para predecir los procesos de aprendizaje de los alumnos. Los grupos que se encuentran en los extremos de las dimensiones establecidas por las variables del análisis son el grupo “orientado a la actividad (enfoque social)” y el

grupo “no orientado a la actividad (procrastinadores)”, que son claramente opuestos en términos de dedicación a la actividad y en los días que tardan en entregar la actividad. Precisamente, *acciones relevantes*, junto con estas dos variables (*tiempo actividad* y *días entrega*) y *palabras foro* son las variables más adecuadas para predecir el proceso de aprendizaje. Sin embargo, *acciones relevantes* es una variable compleja, puesto que se basa en el número de acciones que realiza el alumno en el LMS y los clusters con mejor rendimiento presentan valores negativos en esta variable. Quizás sucede con esta variable lo mismo que con la interpretación del tiempo de estudio: los estudiantes que estudian más, deberían obtener mejores rendimientos, pero no es así, depende principalmente de la calidad del tiempo de estudio (Plant et al., 2005). Por tanto, mayor número de acciones no necesariamente implica mejores resultados, puesto que esta variable está vinculada a las otras variables que forman parte del proceso de aprendizaje.

Relacionando estos resultados con el modelo de adaptación propuesto, pudiera ser que los grupos “no orientados a la actividad”, necesiten una adaptación completa; mientras que los grupos “orientados a la actividad”, podrían mejorar simplemente con un sistema recomendador, recibiendo un aprendizaje menos conductista en el LMS. Sin embargo, decidir cuándo y cómo implementar la adaptación es uno de los interrogantes de este trabajo en particular, y del e-Learning adaptativo en general (Lavie y Meyer, 2010). Además, si bien se identifican patrones de comportamiento diferentes, los resultados obtenidos no permiten explicar cómo, a pesar de la diversidad de los patrones, los rendimientos obtenidos, en determinados casos, son similares.

Con respecto a la procrastinación, se ha confirmado la relación de diferentes variables de procrastinación con el rendimiento académico en los LMSs. Aquellos alumnos que desarrollan las actividades pronto, o dentro de la media, y dedicándoles el tiempo suficiente, obtienen un mejor rendimiento. Sin embargo, los alumnos que no gestionan bien el tiempo (en términos de consultar y tiempo dedicado a las actividades y al estudio) son incapaces de cumplir los mínimos, obteniendo un rendimiento bajo. Por otra parte, se ha comprobado que la unión de variables relacionadas con el tiempo de trabajo, esfuerzo, y procrastinación pueden emplearse como predictores del rendimiento obtenido por los alumnos en un LMS. Se han obtenidos tres reglas de asociación, cuyos antecedentes relacionan inversamente la procrastinación y el rendimiento. Se ha obtenido una regla que predice el rendimiento alto de los alumnos está basada en procesos de aprendizaje organizados. Las otras dos reglas predicen el rendimiento de los alumnos. La primera de

ellas, está basada exclusivamente en variables de procrastinación, mientras que la segunda y la tercera, incluyen tanto variables de procrastinación, como de esfuerzo y tiempo de trabajo. A pesar que la interacción final de los alumnos en un LMS no se obtiene hasta que ya han finalizado el curso y, por tanto, ya han sido evaluados, la demostración de que estas reglas prevalecen en años académicos sucesivos, supone una fuente valiosa para implementar sistemas de feedback tanto para los docentes, como para los alumnos. Aún así, tal y como indican trabajos previos (Choi y Moran, 2009; Kim et al., 2014), es necesario seguir estudiando qué variables de procrastinación se relacionan con los perfiles activos y pasivos de procrastinación.

Teniendo en cuenta la información previamente presentada, puede afirmarse que se ha completado el objetivo fundamental de esta tesis, descubrir nuevas variables de comportamiento en LMSs que se relacionen con el proceso E-A, y que puedan formar parte del modelo de interacción-adaptación para optimizar dicho proceso. Cabe destacar que los estudios realizados se basan en muestras de estudiantes universitarios en el tercer año de carrera, por lo que es probable que los resultados obtenidos varíen ligeramente si utilizamos muestras de estudiantes de primer año, no pudiendo generalizar los resultados obtenidos. En múltiples estudios, se ha evidenciado que los alumnos novatos tienen estrategias de estudio menos sofisticadas para asimilar nuevos dominios de información (Alexander, Sperl, Buehl, Fives, y Chiu, 2004; Murphy y Alexander, 2002).

A continuación, según los resultados obtenidos y las limitaciones presentadas, se presenta qué líneas de trabajo futuras derivan de la presente tesis doctoral.

## 6.1 Trabajo futuro

El trabajo futuro que se presenta a continuación, persigue completar el modelo teórico propuesto, así como evaluar su implementación en diversos contextos, y optimizar el ajuste de la adaptación dinámica para proporcionar, y medir, la mejora en el proceso de E-A.

Se analizará cómo convertir la información obtenida de los patrones de los alumnos en el LMS, en variables de adaptación. Esto permitiría a los docentes generar variables de mayor complejidad, basadas en la interacción de los alumnos con la plataforma e incluirlas en los procesos de adaptación o en un sistema recomendador (Zhang y Zhang,

2002). Un ejemplo claro, podría ser crear una variable denominada “procrastinador”, en función de diversos patrones de comportamiento detectados, tal y como recomiendan estudios previos (Choi y Moran, 2009; Kim et al., 2014).

Estudiar en profundidad cómo los alumnos que tienen diferentes patrones en los LMSs obtienen rendimientos similares. Para cumplir este objetivo, sería necesario cruzar los datos presentados con otro tipo de medidas como los autoinformes sobre SRL y la actividad metacognitiva, siendo posible emplear el modelo aquí presentado para llevar a cabo la investigación. El MSQ (Motivated Strategies for Learning Questionnaire) (Pintrich, Smith, Garcia, y McKeachie, 1993) o el WSSRQ (Web Supported Self-Regulation Questionnaire) (Dabbagh y Kitsantas, 2005), podrían ser útiles para alcanzar este objetivo. Además, existen trabajos previos que muestran relaciones interesantes entre variables obtenidas de ficheros logs y variables obtenidas a través de autoinformes, como las metas de logro (Wäschle, Allgaier, Lachner, Fink, y Nückles, 2014). En este sentido, relacionar la medición de variables psicológicas con métodos clásicos para entender el proceso de aprendizaje es un tema en auge en esta línea de investigación (Azevedo et al., 2012).

Ampliar el sistema de feedback del modelo propuesto. Los resultados obtenidos, proporcionan una información muy útil acerca de cómo se comportan los alumnos. Por lo tanto, sería interesante incluir en el modelo un sistema de feedback similar a los presentados en otros estudios (Govaerts et al., 2012; Leony et al., 2012).

Con el objetivo de crear una arquitectura flexible, se estudiará cómo extender la arquitectura del modelo para que pueda implementarse en otro tipo de plataformas de e-Learning, como las plataformas orientadas a servicios (Francisco José García-Peñalvo, González, Forment, y Guerrero, 2011; Ros et al., 2013) o sistemas basados en la nube (García-Peñalvo, Cruz-Benito, Maderuelo, Pérez-Blanco, y Martín-Suárez, 2014). Esta evolución, permitiría aplicar el modelo en plataformas emergentes, tales como los Personal Learning Environments (PLEs) o los Massive Open Online Courses (MOOCs).

En consonancia con lo anterior, es necesario replicar los estudios con diferentes muestras de estudiantes y diferentes áreas de conocimiento, con el fin de generalizar los resultados obtenidos en los estudios aquí presentados. Además, la información extraída de los nuevos resultados, podría aportar conocimiento a uno de los mayores problemas

que presenta la adaptación en plataformas e-Learning, cuándo, cómo y a quién adaptar (Lavie y Meyer, 2010).

La materialización de los estudios anteriores, permitirían validar empíricamente la mejora del proceso E-A en el modelo presentado, combinando estos nuevos resultados con los ya obtenidos en la presente tesis. Dado este caso, es probable que el conocimiento que se obtuviera de estos estudios, ayudase a clarificar algunos de los interrogantes presentes en el e-Learning adaptado, generando nuevas líneas de investigación.

Para finalizar, una línea de investigación que deriva de los resultados presentados en esta tesis doctoral, está relacionada con los Learning Dashboards, que se definen como un conjunto de visualizaciones del resultado de aplicar Minería De Datos Educativa (Yoo, Lee, Jo, y Park, 2015) o como la visualización del proceso del aprendizaje (Steiner, Kickmeier-Rust, y Albert, 2014). A pesar de que en los últimos años han crecido en popularidad, uno de los mayores interrogantes aún por resolver de los Learning Dashboards es identificar qué información y cómo debe ser presentada a diferentes usuarios (alumnos en este caso) (Schwendimann et al., 2017). Esta circunstancia encaja con los objetivos del modelo de interacción-adaptación presentado en esta tesis, por lo que sería interesante estudiar cómo adaptar los Learning Dashboards en función de las características del alumno, a través de variables de comportamiento y variables relacionadas con el SRL obtenidas mediante autoinformes, proporcionándole un seguimiento de su aprendizaje adaptado.

# Apéndice A

## Diagramas del prototipo implementado

### A.1 Diagrama de paquetes

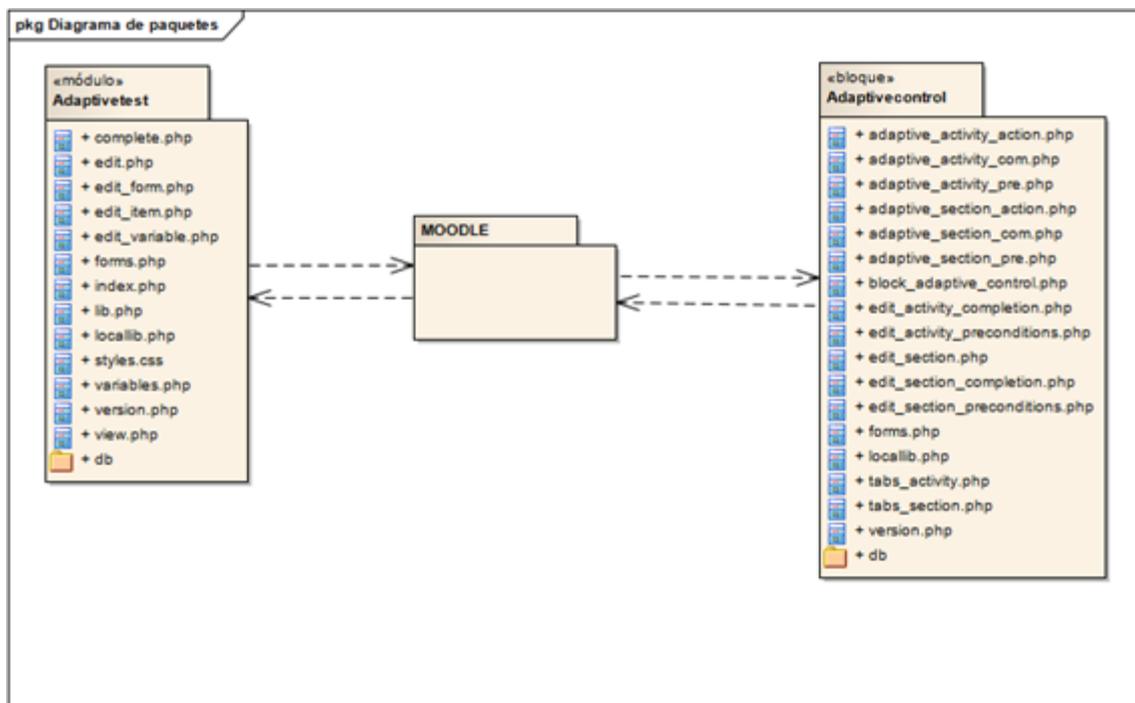


Figura 17. Diagrama de paquetes del prototipo implementado

## A.2 Diagrama de clases del Modelo de usuario

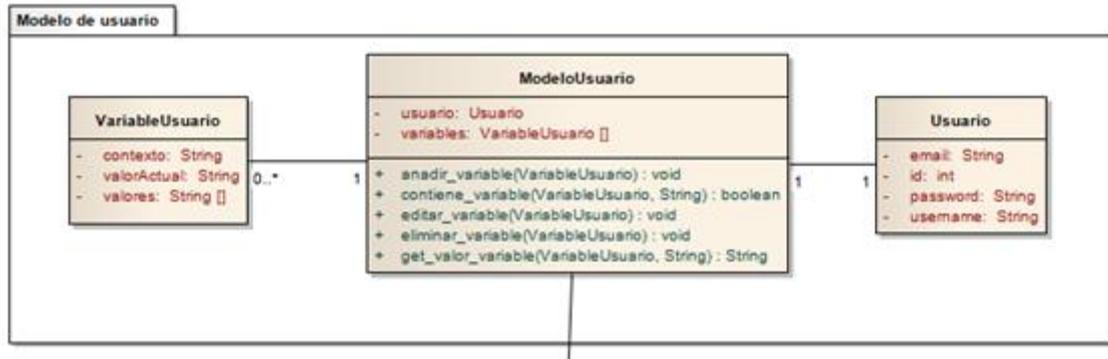


Figura 18. Diagrama de clases del modelo de usuario

## A.3 Diagrama de clases del módulo AdaptiveControl

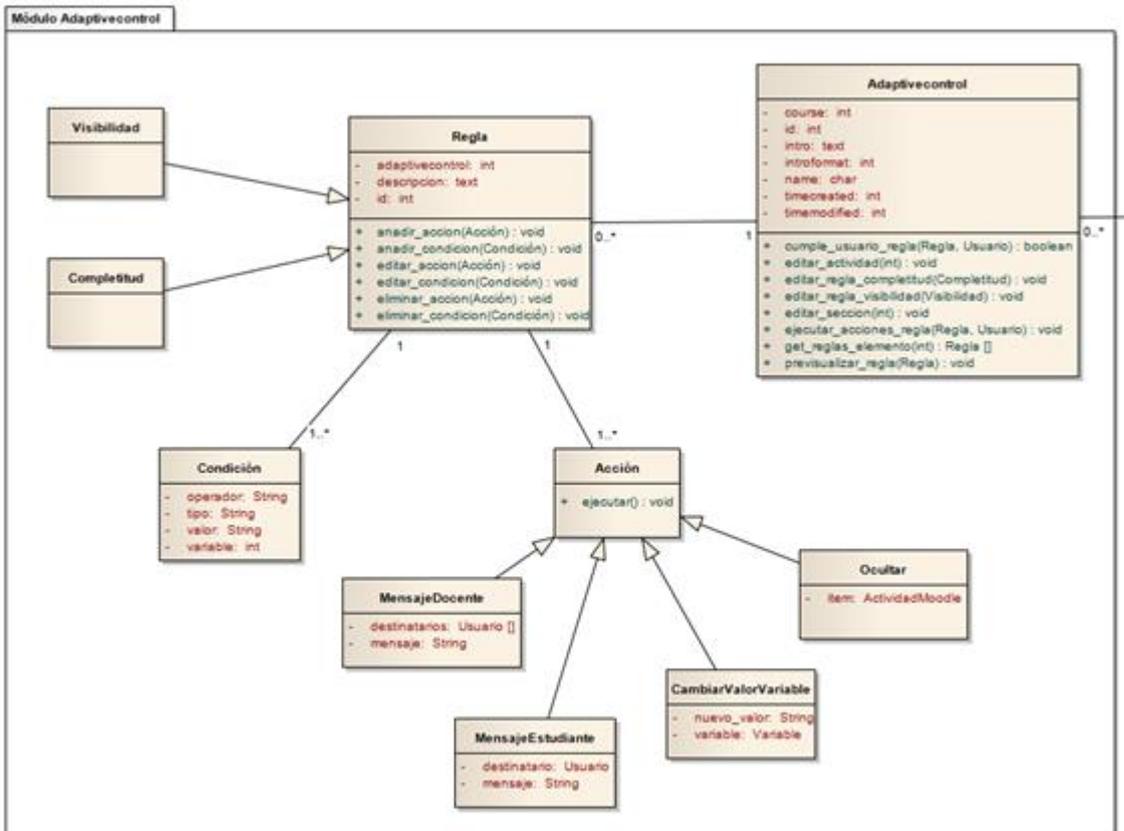


Figura 19. Diagrama de clases del módulo AdaptiveControl

## A.4 Diagrama de clases del módulo AdaptiveTest

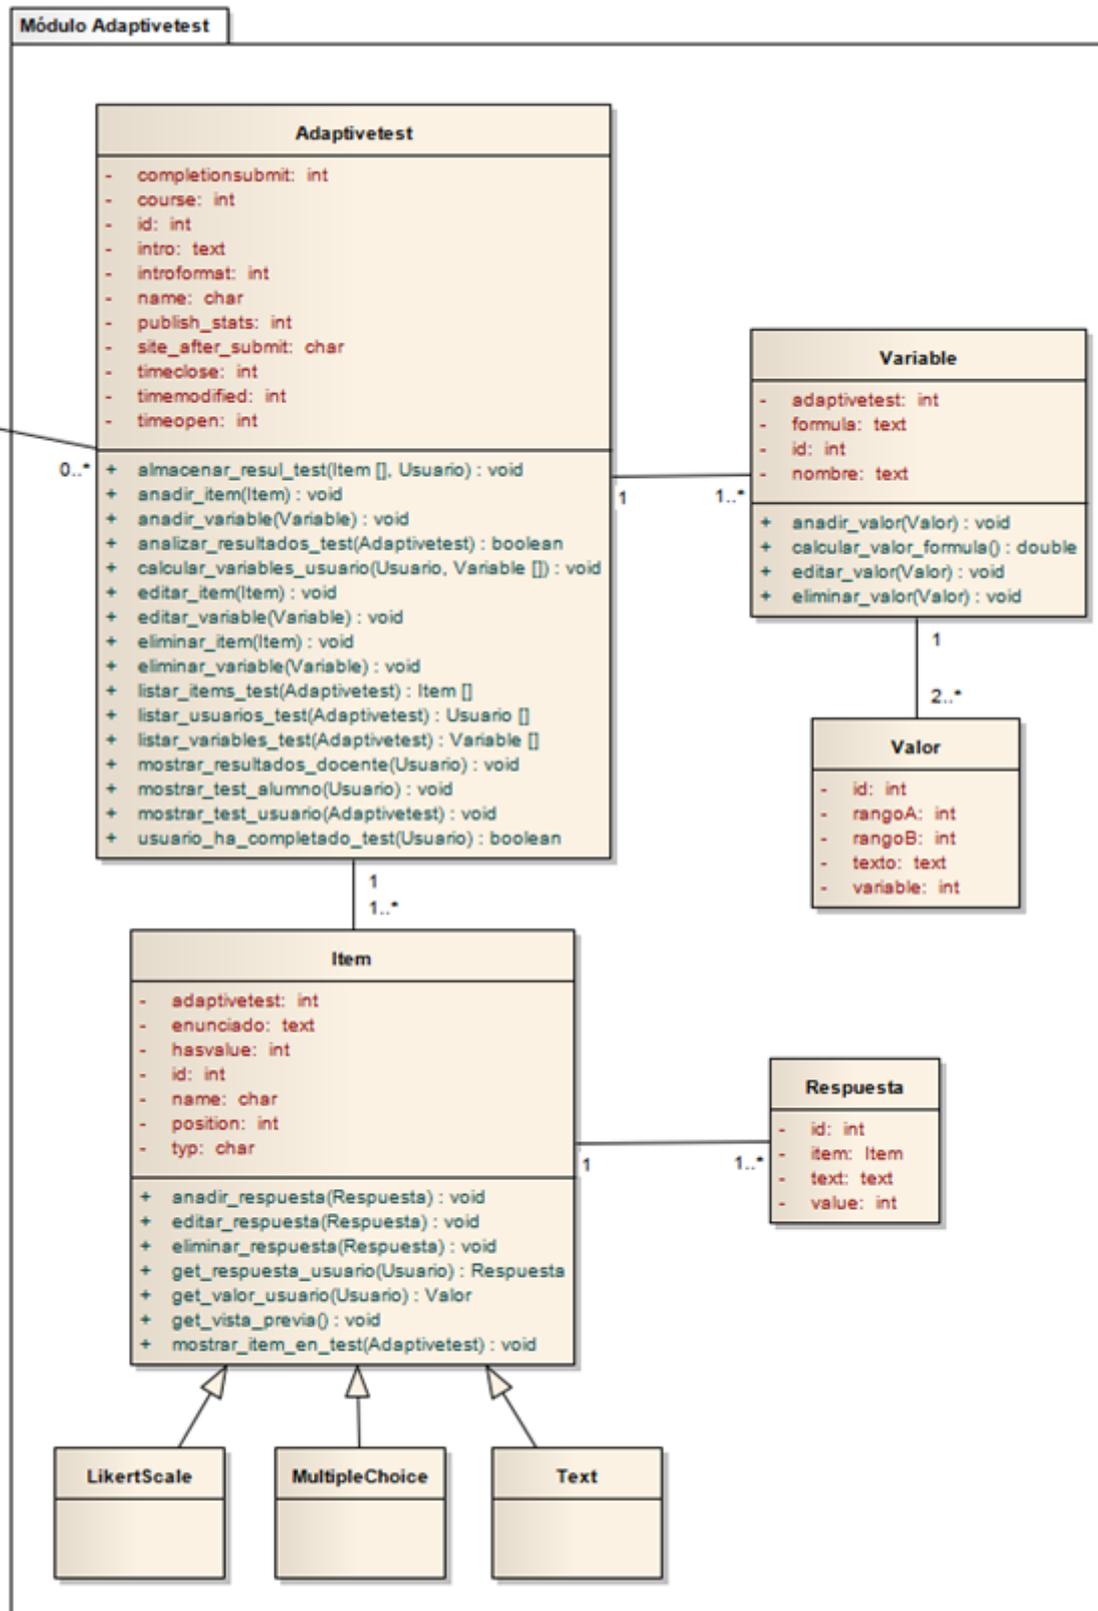


Figura 20. Diagrama de clases del módulo AdaptiveTest

## A.5 Diagrama de actividad del proceso de adaptación

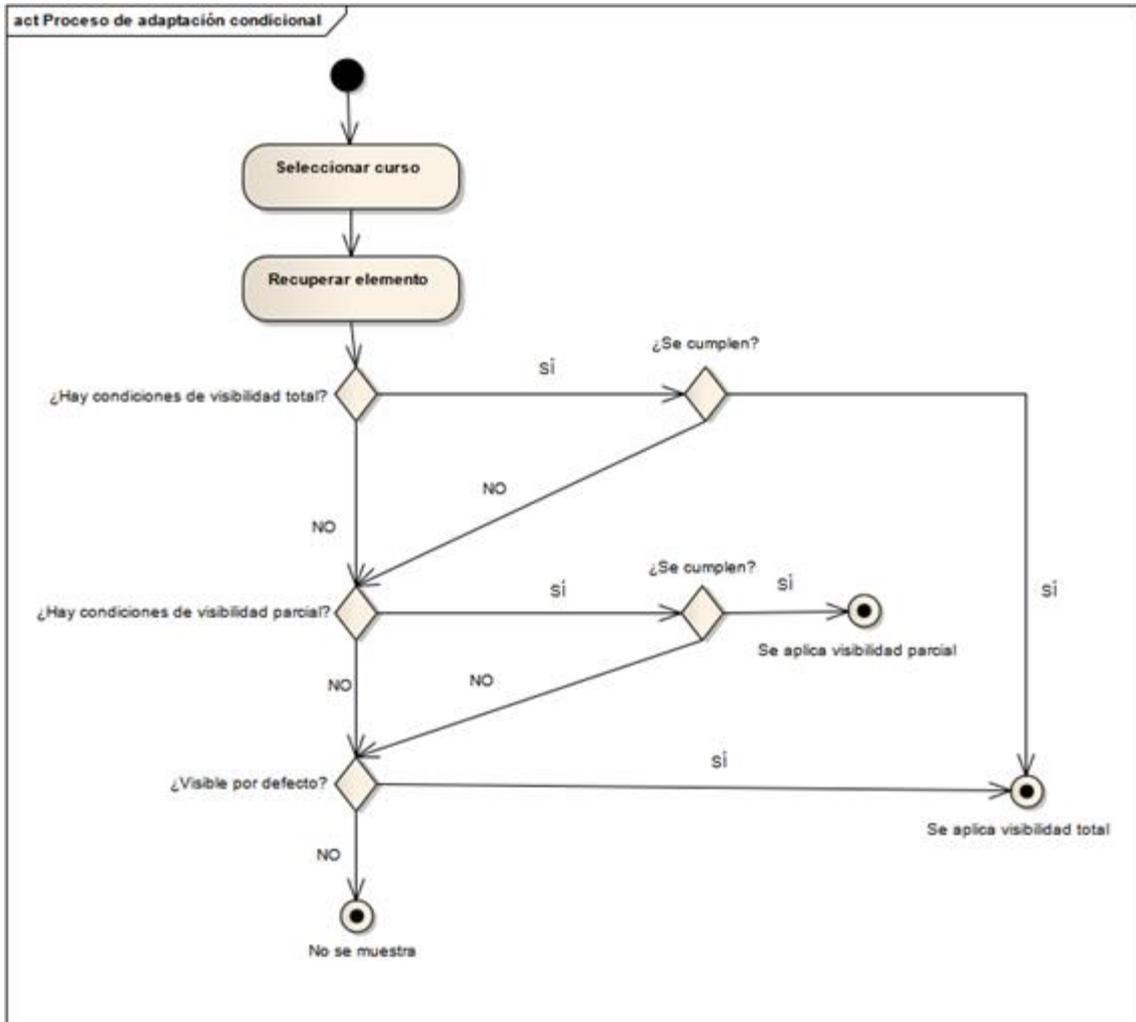


Figura 21. Diagrama de actividad del proceso de adaptación

# Apéndice B

## Items del MSLQ del supuesto teórico

### B.1 Items relativos a la autoeficacia macro

	1	2	3	4	5	6	7
No. Nunca.		Más bien no. Alguna vez.		Más bien sí. Con bastante frecuencia.		Sí. Siempre.	

5. Creo que obtendré muy buenas notas en este curso.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

6. Estoy seguro de que puedo entender incluso los contenidos más difíciles de los libros, lecturas recomendadas y apuntes de las asignaturas de este curso.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

12. Estoy seguro de que puedo aprenderme los conceptos básicos que se enseñan en las diferentes materias.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

15. Estoy seguro de que puedo entender incluso los temas más complicados que expliquen los profesores este curso.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

20. Estoy seguro de que puedo hacer muy bien los trabajos y exámenes de las diferentes asignaturas.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

21. Creo que me irá bien este curso.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

29. Estoy seguro de que puedo dominar las capacidades o técnicas que se enseñan en las diferentes asignaturas.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

31. Teniendo en cuenta la dificultad de las asignaturas, los profesores y mis capacidades, creo que me irá bien este curso.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

## B.2 Items relativos a la orientación a metas intrínsecas

1	2	3	4	5	6	7
No. Nunca.	Más bien no. Alguna vez.	Más bien sí. Con bastante frecuencia.	Sí. Siempre.			

1. Prefiero estudiar temas que sean realmente desafiantes para así aprender cosas nuevas

1	2	3	4	5	6	7
---	---	---	---	---	---	---

16. Prefiero estudiar temas que estimulen mi curiosidad, aunque sean difíciles de aprender.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

22. Lo más satisfactorio para mí es entender los contenidos tan a fondo como me sea posible.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

24. Cuando tengo la oportunidad, escojo las lecturas recomendadas y trabajos con los que puedo aprender más, incluso si éstos no me garantizan una buena nota.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

### B.3 Items relativos a la orientación a metas extrínsecas

1	2	3	4	5	6	7
No. Nunca.	Más bien no. Alguna vez.		Más bien sí. Con bastante frecuencia.		Sí. Siempre.	

7. Sacar buenas notas es lo más importante para mí en este momento.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

11. Lo más importante para mí ahora es mejorar mi expediente, así que mi preocupación principal es sacar buenas notas en este curso.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

13. Si puedo, quiero sacar mejores notas que la mayoría de los alumnos.

1	2	3	4	5	6	7
---	---	---	---	---	---	---

30. Quiero ir bien este curso porque es importante para mí demostrar mi capacidad a mi familia, mis amigos, mi jefe u otras personas.

1	2	3	4	5	6	7
---	---	---	---	---	---	---



# Apéndice C

## Acciones registradas en logs de Moodle

Módulo	Acciones tipo view	Acciones tipo post
Assignment	view	upload
Chat	View, view all, report	Talk
Choice	View, view all	Choose, choose again
Database	View	Add, update, record delete
Forum	View discussion, search, forum, fóruns, subscribers	Add discussion, add post, delete discussion, delete post, move discussion, prune post, update post
Glossary	View, view all, view entry	Add category, add comment, add entry, approve entry, delete category, delete comment, delete entry, edit category, update comment, update entry
Hot Potatoes Quiz	View, view all, report	Attempt, review, submit
Journal	View, view all, report	Add entry, update entry, update feedback
Lesson	View, view all	End, start, update grade attempt
Quiz	View, view all, report	Attempt, edit questions, review, submit
Resource	View, view all	-
SCORM/AICC	Preview, view, view all, report	-
Survey	Download, view all, view form, view graph, view report	submit

**Tabla 10.** Acciones registradas en los logs de Moodle



# Apéndice D

## Publicaciones

A continuación, se detalla la disseminación científica de esta tesis doctoral, tanto en publicaciones, como en congresos.

- Los siguientes artículos están publicados en revistas incluídas en el Journal Citation Reports a fecha de depósito:
  1. Paule-Ruiz, M., Riestra-Gonzalez, M., Sánchez-Santillan, M., y Pérez-Pérez, J. R. (2015). The Procrastination Related Indicators in e-Learning Platforms. *Journal of Universal Computer Science*, 21(1), 7-22. (JCR), IP: 0,546.
  2. Sánchez-Santillán, M., Paule-Ruiz, M., Cerezo, R., y Álvarez-García, V. (2016). MeL: modelo de adaptación dinámica del proceso de aprendizaje en eLearning. *anales de psicología*, 32(1), 106-114. (JCR), IP: 0,574.
  3. Cerezo, R., Sánchez-Santillán, M., Paule-Ruiz, M. P., y Núñez, J. C. (2016). Students' LMS interaction patterns and their relationship with achievement: A case study in higher education. *Computers & Education*, 96, 42-54. (JCR), IP: 2,881.
- Comunicaciones realizadas en congresos relacionados con los objetivos de esta tesis:
  1. Cerezo, R., Suarez, N., Núñez, J. C., y Sánchez-Santillán, M. (2014, Marzo). eGraph tool: graphing the learning process in LMSs. En *Proceedings of the Fourth International Conference on Learning Analytics And Knowledge* (pp. 273-274). Indianápolis, EEUU. ACM.

2. Bogarín, A., Romero, C., Cerezo, R., y Sánchez-Santillán, M. (2014, Marzo). Clustering for improving educational process mining. En *Proceedings of the Fourth International Conference on Learning Analytics And Knowledge* (pp. 11-15). Indianápolis, EEUU. ACM.
  3. Sanchez-Santillan, M., Paule-Ruiz, M., Cerezo, R., & Nuñez, J. (2016, Abril). Predicting Students' Performance: Incremental Interaction Classifiers. In *Proceedings of the Third (2016) ACM Conference on Learning@ Scale* (pp. 217-220). Edimburgo, Escocia. ACM.
- Capítulos publicados en libros relacionados con los objetivos de esta tesis:
1. Cerezo, R., Álvarez, D., Sánchez-Santillán, M., Núñez, J. C., & Álvarez, L. (2013). Nuevas metodologías para la evaluación del aprendizaje en campus virtuales. *Innovación Educativa en la Educación Superior*, 77-96.
  2. Romero, C., Cerezo, R., Bogarín, A., y Sánchez-Santillán, M. (2016). Educational process mining: a tutorial and case study using moodle data sets. *Data Mining and Learning Analytics: Applications in Educational Research*, 1.

# Referencias

- Abdous, M. 'hammed, He, W., & Yen, C.-J. (2012). Using data mining for predicting relationships between online question theme and final grade. *Educational Technology & Society, 15*(3), 77–88.
- Abel, F., Heckmann, D., Herder, E., Hidders, J., Houben, G.-J., Krause, D., van der Sluijs, K. (2009). Mashing up user data in the Grapple User Modeling Framework. En *LWA* (p. ABIS–1).
- Agarwal, R., Sambamurthy, V., & Stair, R. M. (2000). Research Report: The Evolving Relationship Between General and Specific Computer Self-Efficacy—An Empirical Assessment. *Information Systems Research, 11*(4), 418-430. <https://doi.org/10.1287/isre.11.4.418.11876>
- Agosti, M., Crivellari, F., & Di Nunzio, G. M. (2012). Web log analysis: a review of a decade of studies about information acquisition, inspection and interpretation of user interaction. *Data Mining and Knowledge Discovery, 24*(3), 663–696.
- Akbulut, Y., & Cardak, C. S. (2012). Adaptive educational hypermedia accommodating learning styles: A content analysis of publications from 2000 to 2011. *Computers & Education, 58*(2), 835 - 842. <https://doi.org/10.1016/j.compedu.2011.10.008>
- Alexander, P. A., Sperl, C. T., Buehl, M. M., Fives, H., & Chiu, S. (2004). Modeling domain learning: Profiles from the field of special education. *Journal of educational psychology, 96*(3), 545.
- Alstete, J. W., & Beutell, N. J. (2004). Performance indicators in online distance learning courses: a study of management education. *Quality Assurance in Education, 12*(1), 6–14.

- Area-Moreira, M. (2000). What is the role of the Internet in the pedagogical change at the level of College Education. En *Proceedings of III International Conference of Communication, Technology and Education* (pp. 128–135).
- Arnold, K. E., & Pistilli, M. D. (2012). Course signals at Purdue: Using learning analytics to increase student success. En *Proceedings of the 2nd international conference on learning analytics and knowledge* (pp. 267–270). ACM.
- Asarta, C. J., & Schmidt, J. R. (2013). Access patterns of online materials in a blended course. *Decision Sciences Journal of Innovative Education*, 11(1), 107–123.
- Azevedo, R. (2005). Using Hypermedia as a Metacognitive Tool for Enhancing Student Learning? The Role of Self-Regulated Learning. *Educational Psychologist*, 40(4), 199-209. [https://doi.org/10.1207/s15326985ep4004\\_2](https://doi.org/10.1207/s15326985ep4004_2)
- Azevedo, R. (2015). Defining and measuring engagement and learning in science: Conceptual, theoretical, methodological, and analytical issues. *Educational Psychologist*, 50(1), 84–94.
- Azevedo, R., & Aleven, V. A. (2013). *International handbook of metacognition and learning technologies* (Vol. 26). Springer.
- Azevedo, R., Behnagh, R., Duffy, M., Harley, J., & Trevors, G. (2012). Metacognition and self-regulated learning in student-centered learning environments. D. Jonassen & S. Land. *Theoretical foundations of student-center learning environments*, 171–197.
- Azevedo, R., Cromley, J. G., Moos, D. C., Greene, J. A., & Winters, F. I. (2011). Adaptive content and process scaffolding: A key to facilitating students' self-regulated learning with hypermedia. *Psychological Testing and Assessment Modeling*, 53, 106–140.

- Azevedo, R., Cromley, J., Winters, F., Moos, D., & Greene, J. (2005). Adaptive Human Scaffolding Facilitates Adolescents' Self-regulated Learning with Hypermedia. *Instructional Science*, 33(5), 381-412. <https://doi.org/10.1007/s11251-005-1273-8>
- Azevedo, R., & Feyzi-Behnagh, R. (2011). Dysregulated Learning with Advanced Learning Technologies. *Journal of E-Learning and Knowledge Society - English Version*, 7(2).
- Azevedo, R., & Witherspoon, A. M. (2009). Self-regulated use of hypermedia. *Handbook of metacognition in education*, 319–339.
- Azevedo, R., Witherspoon, A. M., Chauncey, A., Burkett, C., & Fike, A. (2009). MetaTutor: A MetaCognitive Tool for Enhancing Self-Regulated Learning. En *AAAI Fall Symposium: Cognitive and Metacognitive Educational Systems*.
- Baker, R. S., Lindrum, D., Lindrum, M. J., & Perkowski, D. (2015). Analyzing Early At-Risk Factors in Higher Education E-Learning Courses. *International Educational Data Mining Society*.
- Balkis, M. (2011). Academic efficacy as a mediator and moderator variable in the relationship between academic procrastination and academic achievement. *Eğitim Araştırmaları Dergisi*, 45, 1–16.
- Biggs, J. (1979). Individual differences in study processes and the quality of learning outcomes. *Higher education*, 8(4), 381–394.
- Biggs, J., & Biggs, J. B. (2004). *Calidad del aprendizaje universitario* (Vol. 7). Narcea ediciones.
- Bra, P. D., & Calvi, L. (1998). AHA! An open Adaptive Hypermedia Architecture. *New Review of Hypermedia and Multimedia*, 4(1), 115-139. <https://doi.org/10.1080/13614569808914698>

- Brooks, C. A., Thompson, C., & Kovanović, V. (2016). Introduction to data mining for educational researchers. En *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge* (pp. 505–506). ACM.
- Brown, A. (1987). Metacognition, executive control, self-regulation and other more mysterious mechanisms. En *Metacognition, motivation, and understanding* (pp. 65-116). Erlbaum.
- Brusilovsky, P. (1996). Methods and techniques of adaptive hypermedia. *User Modeling and User-Adapted Interaction*, 6(2), 87-129. <https://doi.org/10.1007/BF00143964>
- Brusilovsky, P. (2001). Adaptive Hypermedia. *User Modeling and User-Adapted Interaction*, 11(1), 87-110. <https://doi.org/10.1023/A:1011143116306>
- Brusilovsky, P. (2003). Adaptive navigation support in educational hypermedia: the role of student knowledge level and the case for meta-adaptation. *British Journal of Educational Technology*, 34(4), 487–497. <https://doi.org/10.1111/1467-8535.00345>
- Butler, D. L., & Winne, P. H. (1995). Feedback and Self-Regulated Learning: A Theoretical Synthesis. *Review of Educational Research*, 65(3), 245-281. <https://doi.org/10.3102/00346543065003245>
- Cerezo, R., Bernardo, A., Esteban, M., Sánchez, M., & Tuero, E. (2015). Programas para la promoción de la autorregulación en educación superior: un estudio de la satisfacción diferencial entre metodología presencial y virtual. *European Journal of Education and Psychology*, 8(1), 30–36.
- Cerezo, R., Núñez Pérez, J. C., Rosário, P., Valle, A., Rodríguez, S., & Bernardo, A. (2010). New media for the promotion of self-regulated learning in higher education. *Psicothema*, 22(2), 306–315.

- 
- Cerezo, R., Sánchez-Santillán, M., Paule-Ruiz, M. P., & Núñez, J. C. (2016). Students' LMS interaction patterns and their relationship with achievement: A case study in higher education. *Computers & Education, 96*, 42–54.
- Choi, J. N., & Moran, S. V. (2009). Why not procrastinate? Development and validation of a new active procrastination scale. *The Journal of social psychology, 149*(2), 195–212.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* Lawrence Erlbaum Associates. *Hillsdale, NJ*, 20–26.
- Cole, J., & Foster, H. (2007). *Using Moodle: Teaching with the popular open source course management system*. O'Reilly Media, Inc.
- Cristea, A. I., & De Mooij, A. (2003). LAOS: Layered WWW AHS authoring model and their corresponding algebraic operators. En *Proc. of 12th WWW Conference*. Budapest, Hungary.
- Cristea, A., Smits, D., Bevan, J., & Hendrix, M. (2009). LAG 2.0: Refining a Reusable Adaptation Language and Improving on Its Authoring. En U. Cress, V. Dimitrova, & M. Specht (Eds.), *Learning in the Synergy of Multiple Disciplines* (Vol. 5794, pp. 7-21). Springer Berlin / Heidelberg.
- Cristea, A., Smits, D., & de Bra, P. (2005). Writing MOT, reading AHA. *Converting between an authoring and a delivery system for adaptive educational hypermedia*, University of Technology, Eindhoven.
- Dabbagh, N., & Kitsantas, A. (2005). Using web-based pedagogical tools as scaffolds for self-regulated learning. *Instructional Science, 33*(5), 513–540.

- Dabbagh, N., & Kitsantas, A. (2013). Using learning management systems as metacognitive tools to support self-regulation in higher education contexts. En *International handbook of metacognition and learning technologies* (pp. 197–211). Springer.
- Dagger, D., O'Connor, A., Lawless, S., Walsh, E., & Wade, V. P. (2007). Service-Oriented E-Learning Platforms: From Monolithic Systems to Flexible Services. *IEEE Internet Computing*, 11(3), 28–35. <https://doi.org/10.1109/MIC.2007.70>
- David Hauger, & Köck, M. (2008). *State of the Art of Adaptivity in E-Learning Platforms*. CiteSeerX.
- Dawson, S. P., Macfadyen, L., & Lockyer, L. (2009). Learning or performance: Predicting drivers of student motivation.
- De Bra, P., Smits, D., Van Der Sluijs, K., Cristea, A. I., Foss, J., Glahn, C., & Steiner, C. M. (2013). GRAPPLE: Learning management systems meet adaptive learning environments. En *Intelligent and adaptive educational-learning systems* (pp. 133–160). Springer.
- De Bra, P., Stash, N., Smits, D., Romero, C., & Ventura, S. (2007). Authoring and management tools for adaptive educational hypermedia systems: The AHA! case study. En *Evolution of Teaching and Learning Paradigms in Intelligent Environment* (pp. 285–308). Springer.
- del Puerto Paule-Ruiz, M., Riestra-Gonzalez, M., Sánchez-Santillan, M., & Pérez-Pérez, J. R. (2015). The Procrastination Related Indicators in e-Learning Platforms. *Journal of Universal Computer Science*, 21(1), 7–22.
- Dempster, A. P., Laird, N. M., & Rubin, D. B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the royal statistical society. Series B (methodological)*, 1–38.

- Devolder, A., van Braak, J., & Tondeur, J. (2012). Supporting self-regulated learning in computer-based learning environments: systematic review of effects of scaffolding in the domain of science education. *Journal of Computer Assisted Learning, 28*(6), 557–573.
- Dickinson, D. J., & O’Connell, D. Q. (1990). Effect of quality and quantity of study on student grades. *The Journal of Educational Research, 83*(4), 227–231.
- Duval, E. (2011). Attention please!: learning analytics for visualization and recommendation. En *Proceedings of the 1st International Conference on Learning Analytics and Knowledge* (pp. 9–17). New York, NY, USA: ACM. <https://doi.org/10.1145/2090116.2090118>
- Duval, E., Klerkx, J., Verbert, K., Nagel, T., Govaerts, S., Parra Chico, G. A., ... Vandeputte, B. (2012). Learning dashboards & learnsapes. En *Educational Interfaces, Software, and Technology*, (pp. 1–5).
- Essa, A., & Ayad, H. (2012). Student Success System: Risk Analytics and Data Visualization Using Ensembles of Predictive Models. En *Proceedings of the 2Nd International Conference on Learning Analytics and Knowledge* (pp. 158–161). New York, NY, USA: ACM. <https://doi.org/10.1145/2330601.2330641>
- European Commission. (2014). *New modes of learning and teaching in higher education*. Luxembourg: Publications Office of the European Union.
- Formann, A. K. (1984). Latent Class Analysis. *Encyclopedia of Statistical Sciences*.
- Foss, J. G. K., & Cristea, A. I. (2010). The next generation authoring adaptive hypermedia: using and evaluating the MOT3.0 and PEAL tools. En *Proceedings of the 21st ACM conference on Hypertext and hypermedia* (pp. 83–92). New York, NY, USA: ACM. <https://doi.org/10.1145/1810617.1810633>

- Gafni, R., & Geri, N. (2010). Time management: Procrastination tendency in individual and collaborative tasks. *Interdisciplinary Journal of Information, Knowledge, and Management*, 5, 115–125.
- García, E., Romero, C., Ventura, S., & De Castro, C. (2011). A collaborative educational association rule mining tool. *The Internet and Higher Education*, 14(2), 77–88.
- García-Peñalvo, F. J., Cruz-Benito, J., Maderuelo, C., Pérez-Blanco, J. S., & Martín-Suárez, A. (2014). Usalpharma: a cloud-based architecture to support quality assurance training processes in health area using virtual worlds. *The Scientific World Journal*, 2014.
- García-Peñalvo, F. J., González, M. Á. C., Forment, M. A., & Guerrero, M. J. C. (2011). Opening learning management systems to personal learning environments. *J. UCS*, 17(9), 1222–1240.
- García-Peñalvo, F. J., & Pardo, A. M. S. (2015). An updated review of the concept of eLearning. Tenth anniversary. *Education in the Knowledge Society*, 16(1), 119.
- García, V. M. Á., Ruiz, M. del P. P., van Dort, R., & Pérez, J. R. P. (2010). RSS-Based Learning Using Audio. *International Journal of Human Capital and Information Technology Professionals*, 1(4), 76-87.  
<https://doi.org/10.4018/jhcitp.2010100105>
- Glahn, C., Specht, M., & Koper, R. (2007). Smart Indicators on Learning Interactions. En E. Duval, R. Klamma, & M. Wolpers (Eds.), *Creating New Learning Experiences on a Global Scale* (pp. 56-70). Springer Berlin Heidelberg.
- Goda, Y., Yamada, M., Kato, H., Matsuda, T., Saito, Y., & Miyagawa, H. (2015). Procrastination and other learning behavioral types in e-learning and their relationship with learning outcomes. *Learning and Individual Differences*, 37, 72–80.

- Govaerts, S., Verbert, K., Duval, E., & Pardo, A. (2012). The student activity meter for awareness and self-reflection. En *CHI'12 Extended Abstracts on Human Factors in Computing Systems* (pp. 869–884). ACM.
- Graf, S., Liu, T.-C., & others. (2009). Supporting teachers in identifying students' learning styles in learning management systems: An automatic student modelling approach. *Journal of Educational Technology & Society*, 12(4), 3.
- Greene, J. A., Costa, L.-J., Robertson, J., Pan, Y., & Deekens, V. M. (2010). Exploring relations among college students' prior knowledge, implicit theories of intelligence, and self-regulated learning in a hypermedia environment. *Computers & Education*, 55(3), 1027-1043. <https://doi.org/10.1016/j.compedu.2010.04.013>
- Greene, J. A., Moos, D. C., & Azevedo, R. (2011). Self-regulation of learning with computer-based learning environments. *New directions for teaching and learning*, 2011(126), 107–115.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). The WEKA data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1), 10–18.
- Howell, A. J., & Watson, D. C. (2007). Procrastination: Associations with achievement goal orientation and learning strategies. *Personality and Individual Differences*, 43(1), 167–178.
- Hrastinski, S. (2006). Introducing an informal synchronous medium in a distance learning course: how is participation affected? *The Internet and Higher Education*, 9(2), 117–131.
- Hung, J.-L., & Zhang, K. (2008). Revealing online learning behaviors and activity patterns and making predictions with data mining techniques in online teaching. *MERLOT Journal of Online Learning and Teaching*.

- Jacobs, J. E., & Paris, S. G. (1987). Children's Metacognition About Reading: issues in Definition, Measurement, and Instruction. *Educational Psychologist*, 22(3-4), 255-278. <https://doi.org/10.1080/00461520.1987.9653052>
- Jacobson, C. M. (2008). Knowledge sharing between individuals. En *Knowledge Management: Concepts, Methodologies, Tools, and Applications* (pp. 1633–1642). IGI Global.
- Karatas, H. (2015). Correlation among academic procrastination, personality traits, and academic achievement. *Anthropologist*, 20(1), 2.
- Kardan, A. A., Saryazdi, N. G., & Mirashk, H. (2012). Learner clustering and association rule mining for content recommendation in self-regulated learning. *International Journal of Computer Science Research and Application*, 2(1), 69–78.
- Katz, I., Eilat, K., & Nevo, N. (2014). «I'll do it later»: Type of motivation, self-efficacy and homework procrastination. *Motivation and Emotion*, 38(1), 111–119.
- Khribi, M. K., Jemni, M., & Nasraoui, O. (2009). Toward integrating the pedagogical dimension in automatic learner modeling within e-learning systems. En *Advanced Learning Technologies, 2009. ICALT 2009. Ninth IEEE International Conference on* (pp. 642–644). IEEE.
- Kim, J. H., Park, Y., Song, J., & Jo, I.-H. (2014). Predicting students' learning achievement by using online learning patterns in blended learning environments: comparison of two cases on linear and non-linear model. En *Educational Data Mining 2014*.
- Kim, K. R., & Seo, E. H. (2015). The relationship between procrastination and academic performance: A meta-analysis. *Personality and Individual Differences*, 82, 26–33.

- 
- Klingsieck, K. B., Fries, S., Horz, C., & Hofer, M. (2012). Procrastination in a distance university setting. *Distance Education*, 33(3), 295–310.
- Kotsiantis, S., & Kanellopoulos, D. (2006). Association rules mining: A recent overview. *GESTS International Transactions on Computer Science and Engineering*, 32(1), 71–82.
- Kupczynski, L., Gibson, A. M., Ice, P., Richardson, J., & Chaloo, L. (2011). The impact of frequency on achievement in online courses: A study from a South Texas University.
- Lajoie, S. P., & Azevedo, R. (2006). Teaching and learning in technology-rich environments. *Handbook of educational psychology*, 2, 803–821.
- Lavie, T., & Meyer, J. (2010). Benefits and costs of adaptive user interfaces. *International Journal of Human-Computer Studies*, 68(8), 508–524.
- Lehmann, T., Hähnlein, I., & Ifenthaler, D. (2014). Cognitive, metacognitive and motivational perspectives on prelection in self-regulated online learning. *Computers in Human Behavior*, 32, 313–323.
- Leony, D., Pardo, A., de la Fuente Valentín, L., de Castro, D. S., & Kloos, C. D. (2012). GLASS: a learning analytics visualization tool. En *Proceedings of the 2nd international conference on learning analytics and knowledge* (pp. 162–163). ACM.
- Levy, Y., & Ramim, M. M. (2012). A study of online exams procrastination using data analytics techniques. *Interdisciplinary Journal of E-Learning and Learning Objects*, 8(1), 97–113.

- Lopez, M. I., Luna, J. M., Romero, C., & Ventura, S. (2012). Classification via clustering for predicting final marks based on student participation in forums. En *Proceedings of the 5th International Conference on Educational Data Mining, EDM 2012* (pp. 148–151).
- Luna, J. M., Romero, C., Romero, J. R., & Ventura, S. (2015). An evolutionary algorithm for the discovery of rare class association rules in learning management systems. *Applied Intelligence*, 42(3), 501–513.
- Lust, G., Collazo, N. A. J., Elen, J., & Clarebout, G. (2012). Content Management Systems: Enriched learning opportunities for all? *Computers in Human Behavior*, 28(3), 795–808.
- Lust, G., Elen, J., & Clarebout, G. (2013a). Measuring students' strategy-use within a CMS supported course through students' tool-use patterns. En *Book of Abstracts 15th Biennial Conference EARLI 2013* (pp. 571–572).
- Lust, G., Elen, J., & Clarebout, G. (2013b). Regulation of tool-use within a blended course: Student differences and performance effects. *Computers & Education*, 60(1), 385–395.
- Lust, G., Vandewaetere, M., Ceulemans, E., Elen, J., & Clarebout, G. (2011). Tool-use in a blended undergraduate course: In Search of user profiles. *Computers & Education*, 57(3), 2135–2144.
- Lykourantzou, I., Giannoukos, I., Mpardis, G., Nikolopoulos, V., & Loumos, V. (2009). Early and dynamic student achievement prediction in e-learning courses using neural networks. *Journal of the American Society for Information Science and Technology*, 60(2), 372–380.

- Macfadyen, L. P., & Dawson, S. (2010). Mining LMS data to develop an «early warning system» for educators: A proof of concept. *Computers & education*, 54(2), 588–599.
- Manly, B. F. (2004). *Multivariate statistical methods: a primer*. CRC Press.
- Merceron, A., & Yacef, K. (2008). Interestingness measures for association rules in educational data. En *Educational Data Mining 2008*.
- Michinov, N., Brunot, S., Le Bohec, O., Juhel, J., & Delaval, M. (2011). Procrastination, participation, and performance in online learning environments. *Computers & Education*, 56(1), 243–252.
- Moos, D. C., & Azevedo, R. (2008). Self-regulated learning with hypermedia: The role of prior domain knowledge. *Contemporary Educational Psychology*, 33(2), 270–298. <https://doi.org/10.1016/j.cedpsych.2007.03.001>
- Morueta, R. T., Rodríguez, M. A. P., & Gómez, J. I. A. (2011). Blended e-learning en universidades andaluzas. *Aula abierta*, 39(2), 47-58.
- Mosharraf, M., & Taghiyareh, F. (2012). Improving Student Success Rates Through a Semi-Personalized Feedback System. *Proceedings of the 11th European Conference on e-Learning: ECEL*, 364.
- Munoz-Organero, M., Munoz-Merino, P. J., & Kloos, C. D. (2010). Student behavior and interaction patterns with an LMS as motivation predictors in e-learning settings. *IEEE Transactions on Education*, 53(3), 463–470.
- Murphy, P. K., & Alexander, P. A. (2002). What counts? The predictive powers of subject-matter knowledge, strategic processing, and interest in domain-specific performance. *The Journal of Experimental Education*, 70(3), 197–214.

- Murray, M. C., Pérez, J., Geist, D. B., & Hedrick, A. (2012). Student interaction with online course content: Build it and they might come. *Journal of Information Technology Education: Research*, 11(1), 125.
- Muruganathan, V., & ShivaKumar, B. L. (2016). An adaptive educational data mining technique for mining educational data models in elearning systems. *Indian Journal of Science and Technology*, 9(3).
- Neuhauser, C. (2002). Learning style and effectiveness of online and face-to-face instruction. *The American Journal of Distance Education*, 16(2), 99–113.
- Nicol, D. J., & Macfarlane-Dick, D. (2006). Formative assessment and self-regulated learning: a model and seven principles of good feedback practice. *Studies in Higher Education*, 31(2), 199-218. <https://doi.org/10.1080/03075070600572090>
- Núñez, J. C., Cerezo, R., Bernardo, A., Rosário, P., Valle, A., Fernández, E., & Suárez, N. (2011). Implementation of training programs in self-regulated learning strategies in Moodle format: Results of a experience in higher education. *Psicothema*, 23(2), 274–281.
- Núñez, J. C., Solano, P., González-Pienda, J. A., & Rosário, P. (2006). Evaluación de los procesos de autorregulación mediante autoinforme. *Psicothema*, 18(3), 353–358.
- Özpolat, E., & Akar, G. B. (2009). Automatic detection of learning styles for an e-learning system. *Computers & Education*, 53(2), 355–367.
- Pike, G. R., & Kuh, G. D. (2005). First-and second-generation college students: A comparison of their engagement and intellectual development. *The Journal of Higher Education*, 76(3), 276–300.
- Pintrich, P. R. (2000). Multiple goals, multiple pathways: The role of goal orientation in learning and achievement. *Journal of Educational Psychology*, 92(3), 544-555. <https://doi.org/10.1037/0022-0663.92.3.544>

- Pintrich, P. R., & De Groot, E. V. (1990). Motivational and self-regulated learning components of classroom academic performance. *Journal of educational psychology*, 82(1), 33.
- Pintrich, P. R., Smith, D. A. F., Garcia, T., & McKeachJe, W. J. (1991). *A Manual for the Use of the Motivated Strategies for Learning Questionnaire (MSLQ)* (Vol. 48109).
- Pintrich, P. R., Smith, D. A., Garcia, T., & McKeachie, W. J. (1993). Reliability and predictive validity of the Motivated Strategies for Learning Questionnaire (MSLQ). *Educational and psychological measurement*, 53(3), 801–813.
- Plant, E. A., Ericsson, K. A., Hill, L., & Asberg, K. (2005). Why study time does not predict grade point average across college students: Implications of deliberate practice for academic performance. *Contemporary Educational Psychology*, 30(1), 96–116.
- Polson, M. C., & Richardson, J. J. (Eds.). (1988). *Foundations of intelligent tutoring systems*. Hillsdale, NJ, USA: L. Erlbaum Associates Inc.
- QTI, I. (2005). IMS Question & Test Interoperability Specification. *IMS Global Learning Consortium*.
- Quintana, C., Zhang, M., & Krajcik, J. (2005). A Framework for Supporting Metacognitive Aspects of Online Inquiry Through Software-Based Scaffolding. *Educational Psychologist*, 40(4), 235-244.  
[https://doi.org/10.1207/s15326985ep4004\\_5](https://doi.org/10.1207/s15326985ep4004_5)
- Rabin, L. A., Fogel, J., & Nutter-Upham, K. E. (2011). Academic procrastination in college students: The role of self-reported executive function. *Journal of clinical and experimental neuropsychology*, 33(3), 344–357.

- Rodríguez, S., G. Cabanach, R., Piñeiro, I., Valle, A., Núñez, J. C., & González-Piñeda, J. A. (2001). Metas de aproximación, metas de evitación y múltiples metas académicas. *Psicothema*, 13(Número 4), 546-550.
- Romero, C., Espejo, P. G., Zafra, A., Romero, J. R., & Ventura, S. (2013). Web usage mining for predicting final marks of students that use Moodle courses. *Computer Applications in Engineering Education*, 21(1), 135–146.
- Romero, C., Ventura, S., Espejo, P. G., & Hervás, C. (2008). Data mining algorithms to classify students. En *Educational Data Mining 2008*.
- Romero, C., Ventura, S., & García, E. (2008). Data mining in course management systems: Moodle case study and tutorial. *Computers and Education*, 51(1), 368-384.
- Romero, C., Ventura, S., Vasilyeva, E., & Pechenizkiy, M. (2010). Class association rules mining from students' test data. En *Educational Data Mining 2010*.
- Romero, C., Ventura, S., Zafra, A., & Bra, P. de. (2009). Applying Web usage mining for personalizing hyperlinks in Web-based adaptive educational systems. *Computers & Education*, 53(3), 828 - 840. <https://doi.org/10.1016/j.compedu.2009.05.003>
- Romero, M. (2013). COMPARING PROCRASTINATION IN ARTS, SCIENCES, TECHNOLOGY, SOCIAL SCIENCES AND HUMANITIES HIGH SCHOOL STUDENTS. En *EDULEARN13 Proceedings* (pp. 3465–3465). IATED.
- Ros, S., Hernández, R., Robles-Gomez, A., Caminero, A. C., Tobarra, L., & Ruiz, E. S. (2013). Open service-oriented platforms for personal learning environments. *IEEE Internet Computing*, 17(4), 26–31.
- Ruiz, M. del P. P., Díaz, M. J. F., Soler, F. O., & Pérez, J. R. P. (2008). Adaptation in current e-learning systems. *Computer Standards & Interfaces*, 30(1–2), 62-70. <https://doi.org/10.1016/j.csi.2007.07.006>

- Sánchez Hernández, A. M. (2010). Procrastinación académica: un problema en la vida universitaria.
- Sánchez-Santillán, M., Paule-Ruiz, M. P., Cerezo, R., & Álvarez-García, V. (2016). MeL: modelo de adaptación dinámica del proceso de aprendizaje en eLearning. *Anales de Psicología*, 32(1), 106-114. <https://doi.org/10.6018/analesps.32.1.195071>
- Scheffer, T. (2001). Finding association rules that trade support optimally against confidence. En *European conference on principles of data mining and knowledge discovery* (pp. 424–435). Springer.
- Scheiter, K., & Gerjets, P. (2007). Learner Control in Hypermedia Environments. *Educational Psychology Review*, 19(3), 285-307. <https://doi.org/10.1007/s10648-007-9046-3>
- Schraw, G., & Moshman, D. (1995). Metacognitive theories. *Educational Psychology Review*, 7(4), 351-371. <https://doi.org/10.1007/BF02212307>
- Schunk, D. H. (1995). Self-efficacy and education and instruction. En *Self-efficacy, adaptation, and adjustment: Theory, research, and application* (pp. 281-303). New York, NY, US: Plenum Press.
- Schunk, D. H., & Ertmer, P. A. (2000). Self-regulation and academic learning: Self-efficacy enhancing interventions. En M. Boekaerts, P. R. Pintrich, & M. Zeidner (Eds.), *Handbook of self-regulation* (pp. 631-649). San Diego, CA, US: Academic Press.
- Schwendimann, B. A., Rodríguez-Triana, M. J., Vozniuk, A., Prieto, L. P., Boroujeni, M. S., Holzer, A., Dillenbourg, P. (2017). Perceiving Learning at a Glance: A Systematic Literature Review of Learning Dashboard Research. *IEEE Transactions on Learning Technologies*, 10(1), 30-41. <https://doi.org/10.1109/TLT.2016.2599522>

- Sekhavatian, A., & Mahdavi, M. (2011). Application of recommender systems on e-learning environments. *EDULEARN11 Proceedings*, 2679–2687.
- Stash, N. V., Cristea, A. I., & De Bra, P. M. (2004). Authoring of learning styles in adaptive hypermedia: problems and solutions (pp. 114–123). New York, NY, USA: ACM. <https://doi.org/10.1145/1013367.1013387>
- Steiner, C. M., Kickmeier-Rust, M. D., & Albert, D. (2014). Learning analytics and educational data mining: An overview of recent techniques. *Learning Analytics for and in Serious Games*, 6.
- Talavera, L., & Gaudioso, E. (2004). Mining student data to characterize similar behavior groups in unstructured collaboration spaces. En *Workshop on artificial intelligence in CSCL. 16th European conference on artificial intelligence* (pp. 17–23).
- Terry, K. P. S. (2002). *The effects of online time management practices on self-regulated learning and academic self-efficacy*. Virginia Polytechnic Institute and State University.
- Tinajero, C., Castelo, A., Guisande, A., & Páramo, F. (2011). Adaptive teaching and field dependence-independence: instructional implications. *Revista Latinoamericana de Psicología*, 43(3), 497–510.
- Tuckman, B. W. (2005). Relations of academic procrastination, rationalizations, and performance in a web course with deadlines. *Psychological Reports*, 96(3 suppl), 1015–1021.
- Uden, L., Wangsa, I. T., & Damiani, E. (2007). The future of E-learning: E-learning ecosystem. En *Digital EcoSystems and Technologies Conference, 2007. DEST'07. Inaugural IEEE-IES* (pp. 113–117). IEEE.

- Valle, A., Cabanach, R. G., Núñez, J. C., González-Pienda, J., Rodríguez, S., & Piñeiro, I. (2003). Multiple goals, motivation and academic learning. *British Journal of Educational Psychology*, 73(1), 71–87. <https://doi.org/10.1348/000709903762869923>
- Valle, A., Núñez, J. C., Cabanach, R. G., González-Pienda, J. A., Rodríguez, S., Rosário, P., Cerezo, R. (2009). Academic goals and learning quality in higher education students. *The Spanish journal of psychology*, 12(1), 96-105.
- Valle Arias, A., Rodríguez-Ramón G., S., Núñez-Pérez, C. J. C., González-Pienda, J. A., & Rosário, P. (2010). Motivational Profiles and Differences in Affective, Motivational and Achievement Variables. *Universitas Psychologica*, 9(1), 109-121.
- Vargas, O. L., Martínez, C. H., & Uribe, Á. C. (2012). Logro de aprendizaje en ambientes hipermediales: andamiaje autorregulador y estilo cognitivo. *Revista Latinoamericana de Psicología*, 44(2), 13–26.
- Wäschle, K., Allgaier, A., Lachner, A., Fink, S., & Nückles, M. (2014). Procrastination and self-efficacy: Tracing vicious and virtuous circles in self-regulated learning. *Learning and instruction*, 29, 103–114.
- Winne, P. H., & Perry, N. E. (2000). Measuring self-regulated learning.
- Winters, F. I., Greene, J. A., & Costich, C. M. (2008). Self-regulation of learning within computer-based learning environments: A critical analysis. *Educational Psychology Review*, 20(4), 429–444.
- Witten, I. H., Frank, E., Trigg, L. E., Hall, M. A., Holmes, G., & Cunningham, S. J. (1999). Weka: Practical machine learning tools and techniques with Java implementations.

- Yoo, Y., Lee, H., Jo, I.-H., & Park, Y. (2015). Educational dashboards for smart learning: Review of case studies. En *Emerging Issues in Smart Learning* (pp. 145–155). Springer.
- You, J. W. (2015). Examining the Effect of Academic Procrastination on Achievement Using LMS Data in e-Learning. *Journal of Educational Technology & Society*, 18(3), 64-74.
- Zacharis, N. Z. (2015). A multivariate approach to predicting student outcomes in web-enabled blended learning courses. *The Internet and Higher Education*, 27, 44-53. <https://doi.org/10.1016/j.iheduc.2015.05.002>
- Zhang, C., & Zhang, S. (2002). *Association rule mining: models and algorithms*. Springer-Verlag.
- Zimmerman, B. J. (1989). Models of self-regulated learning and academic achievement. En *Self-regulated learning and academic achievement* (pp. 1–25). Springer.
- Zimmerman, B., & Schunk, D. (1989). *Self-regulated learning and academic: Theory, research, and practice*. New York: Springer Verlag.