

Detección del alumno en riesgo en titulaciones de Ciencias de la Salud: aplicación de técnicas de *Learning Analytics*

María Consuelo Saiz Manzanares, Raúl Marticorena Sánchez,
Álvar Arnaiz González, María del Camino Escolar Llamazares y
Miguel Ángel Queiruga Dios
Universidad de Burgos (España)

La forma de enseñar y de aprender en la sociedad del siglo XXI ha cambiado. Actualmente, en un porcentaje alto la docencia se realiza en los *Learning Management System*. Estos sistemas permiten aplicar técnicas de *Learning Analytics*. La utilización de dichas herramientas, facilita, entre otros, conocer el patrón de aprendizaje de los estudiantes y la predicción de los alumnos en riesgo. El objetivo de este estudio fue conocer en orden jerárquico de importancia los patrones de aprendizaje más efectivos de los estudiantes en la plataforma. Se trabajó durante dos cursos académicos con una muestra de 122 estudiantes de Ciencias de la Salud. Los instrumentos utilizados fueron la plataforma Moodle v.3.1 y el análisis de los logs con técnicas de *Machine Learning* de regresión. Los resultados indican que el Modelo de Predicción Lineal Automático detectó en orden de importancia: las visitas medias por día, la realización por parte del estudiante de cuestionarios de autoevaluación, y la consulta al *feedback* del docente. El porcentaje de varianza explicada de estas variables sobre los resultados finales fue de un 50.8%. Asimismo, la efectividad del patrón conductual explicó 64.1% de la varianza de dichos resultados, hallándose tres clústeres de efectividad en el patrón conductual detectado.

Palabras clave: Learning management system, learning analytics, modelo lineal automático, alumno en riesgo, universidad.

Detection of at-risk students with Learning Analytics Techniques. The way of teaching and learning in twenty-first century society continues to change. At present, a high percentage of teaching takes place through Learning Management Systems that apply Learning Analytics Techniques. The use of these tools, among other things, facilitates knowledge of student learning patterns and the detection of at-risk students. The aim of this study is to establish the most effective learning patterns of the students on the platform in a hierarchical order of importance. It was conducted over two academic years with 122 students of Health Sciences. The instruments used were the Moodle v.3.1 platform and the analysis of logs with Machine Learning regression techniques. The results indicated that the Automatic Linear Prediction Model detected by order of importance: average visits per day, student self-assessment questionnaires, and teacher feedback. The percentage variance of the final results explained by these variables was 50.8%. Likewise, the effectiveness of the behavioral pattern explained 64.1% of the variance in those results, finding three clusters of effectiveness in the behavioral patterns that were detected.

Keywords: Learning Management System, learning analytics, automatic lineal model, at-risk students, university.

La técnica de *Learning Analytics* (LA) es una disciplina emergente que permite el análisis online de datos relativos a los resultados y patrones de aprendizaje de los estudiantes. Lo cual facilita la intervención del docente para mejorar los procesos de aprendizaje de sus alumnos y optimizar los entornos donde se efectúa dicho aprendizaje (Saqr, Fors, y Tedre, 2017). Si bien, esta técnica es aún un campo poco explorado en los ámbitos docentes de Ciencias de la Salud, entre otros, y puede ser de gran ayuda para la predicción e identificación del estudiante en riesgo. Recientes estudios han hallado que la utilización por parte de los alumnos de los recursos de aprendizaje que ofrecen los *Learning Management System* (LMS) genera patrones conductuales de aprendizaje que permiten discriminar al estudiante en riesgo y predecir los resultados de aprendizaje. También, facilitan la detección de los patrones conductuales de aprendizaje desarrollados por los estudiantes, tanto en actividades individuales como grupales. Además, los LMS permiten la utilización de recursos hipermedia que potencian el aprendizaje efectivo a través del uso de recursos de simulación, *e-assessment*, *e-support*, *e-personalization* y *e-feedback* (Schneider y Blikstein, 2016). El objetivo final es el de optimizar el proceso de enseñanza-aprendizaje.

Relativo a la predicción de los estudiantes en riesgo, se pueden aplicar distintas técnicas de Aprendizaje Automático o *Machine Learning* como son la Regresión Lineal, el *Support Vector Machine*, los *Ensemble Methods*, los Árboles de Decisión y las Redes Neuronales (Romero y Ventura, 2007). En este trabajo se utilizarán las técnicas de Regresión Lineal, dentro de ellas se pueden diferenciar los siguientes modelos: 1) Modelos Lineales Automáticos, dichos métodos predicen factores en orden jerárquico de importancia. En estos modelos las variables se eligen de forma automática. Dicha técnica se emplea cuando existe un alto número de variables de predicción. 2) Modelos de Regresión Logística Binaria, es un modelo de predicción que se utiliza cuando se tienen valores dicotómicos (apto-no apto), estos modelos aplican la curva de ROC (*Receiver Operating Characteristic*, o Característica Operativa del Receptor) y discriminan falsos positivos. 3) Modelo de Regresión Lineal Múltiple, se utiliza para estudiar la relación entre una variable dependiente y las variables independientes.

Respecto del análisis conductual de los patrones de aprendizaje de los estudiantes, es referencial conocer el tipo de estrategias de aprendizaje que utilizan y dentro de ellas tiene una especial relevancia el uso de las estrategias metacognitivas, ya que su utilización explica el 40% de la varianza de los resultados de aprendizaje (Veenman, Bavelaar, De Wolf, y Van Haaren, 2014). En esta línea, investigaciones recientes (Cerezo, Sánchez-Santillan, Paule-Ruiz, y Núñez, 2016; Sáiz, Marticorena, García-Orsorio, y Díez-Pastor, 2017) han puesto de manifiesto como la predicción de los resultados eficaces de aprendizaje se relaciona con el porcentaje de continuidad conductual del estudiante en la plataforma (media de visitas por día) y dentro de ella, especialmente con la frecuencia en la consulta al *feedback* dado por el docente a las tareas

realizadas así como con la realización de tareas de autoevaluación del aprendizaje (realización de *quizzes*). Por ello, en el estudio de los patrones conductuales de aprendizaje de los estudiantes en los LMS, es necesario partir de un modelo efectivo de patrón conductual que permita, en su caso, una propuesta de implementación de programas personalizados de ayuda al aprendizaje. Para poder conseguir estos resultados también se tienen que aplicar técnicas de minería de datos, *Educational Data Mining* (EDM) (Asif, Merceron, Ali, y Haider, 2017; Romero y Ventura, 2007). Estas técnicas descubren las subsecuencias comunes y encuentran relaciones entre acontecimientos sucesivos. Atendiendo al análisis realizado por Bogarín, Cerezo, y Romero (2017). Dentro de estas técnicas destacan: *Episode Mining*, se basa en los *t-pattern analysis* y, se utiliza para analizar las conductas de aprendizaje de los estudiantes. Los resultados hallados con su aplicación son de gran utilidad para el análisis de cómo se produce SRL y de qué ayudas se pueden dar al estudiante y al docente para mejorar el proceso de enseñanza-aprendizaje (Baker y Corbett, 2014; Bannert, Reimann, y Sonnenberg, 2014; Bouchet, Harley, Trevors, y Azevedo, 2013). Otra técnica relevante es la minería de patrones o *Pattern Mining*, esta técnica ayuda en la detección de patrones conductuales y es muy adecuada para el análisis de registros realizados desde varias aplicaciones (Trcka y Pechenizkiy, 2009). No obstante, en la actualidad hay que considerar que los LMS no tienen incorporadas estas herramientas para un fácil uso por parte del usuario (docente o estudiante). Lo que hace precisa la investigación en este campo (Marticorena, Sáiz, Arnaiz, Escolar, y Queiruga, 2018).

Previsiblemente todas estas técnicas, modelos y métodos permitirán al docente, mejorar el diseño pedagógico de las materias y conseguir una personalización del aprendizaje para sus estudiantes (Sáiz, Marticorena, García-Osorio, Escolar, y Queiruga, 2017). Todo ello, desde la puesta en marcha de sistemas de e-orientación (Sáiz, Marticorena, y García-Osorio, 2017).

Estas líneas de investigación son de especial relevancia en el entorno universitario europeo actual, como indica la Agencia de Calidad ENQA en su informe de 2018. En dicho informe se señala como el estándar de calidad clave para la docencia universitaria el centrar dicha instrucción en el estudiante desde la inclusión de sistemas de aprendizaje de *e-learning* y desde un cuidado diseño del proceso de enseñanza-aprendizaje. Asimismo, este interés queda recogido en el último informe de análisis de la calidad del Sistema Universitario Español de ANECA (2018), que centra el proceso de enseñanza en el aprendizaje del estudiante y en sus resultados dirigidos a conseguir los mejores niveles de inserción laboral en el futuro egreso.

Atendiendo a todo ello, el objetivo de este estudio fue el de conocer en orden jerárquico de importancia las conductas de aprendizaje de los estudiantes en la plataforma UBUVirtual y su relación con los resultados de aprendizaje obtenidos. Todo ello, desde la detección del patrón conductual de aprendizaje más efectivo en el entorno Moodle.

MÉTODO

Participantes

Se trabajó con una muestra de 122 estudiantes de grados en la rama de Ciencias de la Salud: 81 en el Grado en Terapia Ocupacional (GTO) y 41 en el Grado en Enfermería (GE). Los datos descriptivos de la muestra se presentan en la tabla 1.

Tabla 1. N total y parcial y estadísticos descriptivos en la variable edad en las distintas muestras

Grupos	Hombres				Mujeres		
	N	n	M_{edad}	DT_{edad}	n	M_{edad}	DT_{edad}
GTO	81	11	23.64	2.88	70	22.59	2.01
GE	41	5	25.92	3.63	36	24.05	1.23

Nota. M_{edad} =Media de edad; DT_{edad} =Desviación Típica; GTO=Grado en Terapia Ocupacional; GE=Grado en Enfermería

Instrumentos

Plataforma UBUVirtual versión 3.1.

Es un LMS basado en *Modular Object Oriented Dynamic Learning Environment* (Moodle) que parte de un enfoque constructivista y se desarrolla a través de un sistema modular que permite una configuración progresiva. La versatilidad de los módulos y de las actividades facilita en los usuarios (estudiantes y profesores) la fluidez en la interacción que es la base del aprendizaje interactivo (Saeed, Yang, y Sinnappan, 2009).

Escalas de estrategias de aprendizaje (ACRAR) de Román y Poggioli (2013)

Dicho instrumento está altamente contrastado en distintas poblaciones de habla hispana (Carbonero, Román, y Ferrer, 2013) e identifica 32 estrategias en distintos momentos del procesamiento de la información. ACRAR tiene altos niveles de fiabilidad y de validez que se sitúan en un intervalo de $\alpha=.78$; $\alpha=.92$ y $r=.85$; $r=.88$, respectivamente. En este estudio solo se aplicó la Escala de Estrategias Metacognitivas (EEM), y se obtuvo un $\alpha=.74$. En la tabla 2, se presenta la relación de las escalas y las estrategias de ACRAR.

Tabla 2. Estrategias en cada una de las escalas de Metacognición de las ACRAR y de los distintos coeficientes de validez

Escala	Tipo de estrategias	Número de estrategias	Validez interjueces	Validez de constructo	Validez de contenido
Metacognición	autoconocimiento, auto-planificación y autoevaluación	4	$\alpha=.90$	$r=.88$	$r=.88$

Diseño didáctico de la asignatura

En ambos grados las dos asignaturas se diseñaron de forma semejante. Tenían cinco unidades temáticas que se estructuraban en: información sobre la teoría, realización

de una práctica sobre los conocimientos teóricos vistos, realización de un cuestionario de autoevaluación, escala para la evaluación del desarrollo del tema. Además, las unidades temáticas estaban diseñadas desde la metodología de aprendizaje basado en proyectos (ABP) siguiendo el diseño docente propuesto por Sáiz (2018).

Logs de información en la plataforma UBUVirtual

En ellos se registra la información acerca del día y la hora en la que se ha producido la interacción en la plataforma, el usuario que la efectuó, el usuario afectado, el contexto del evento; el componente de la actividad del curso, los archivos enviados, las interacciones en distintos elementos (foros, encuestas, cuestionarios, recursos), el nombre del evento (diferencia entre los tipos vistos en los componentes por ejemplo dentro de la categorización de cuestionarios si hay más de uno) y la descripción (da información sobre el identificador del usuario y del componente).

Procedimiento

Previamente a la realización de este estudio se obtuvo la aprobación por parte de la Comisión de Bioética de la Universidad de Burgos. Posteriormente, se informó a todos los participantes de los objetivos de la investigación y se recabó su consentimiento informado por escrito. Para la elección de la muestra se aplicó un muestreo de conveniencia. Se trabajó con estudiantes de tercero en grados de la rama de Ciencias de la Salud (Grado en Terapia Ocupacional y Grado en Enfermería) en dos asignaturas en las que se aplicó la metodología en Aprendizaje Basado en Proyectos (ABP) en un entorno LMS en concreto en Moodle (UBUVirtual). Las asignaturas se desarrollaron en el segundo semestre en las dos titulaciones y fueron impartidas por el mismo docente a fin de controlar la variable “tipo de profesor”. La instrucción como ya se ha indicado fue semejante en dichas titulaciones utilizando la metodología de ABP. En la primera semana del semestre los estudiantes cumplimentaron la Escala de Estrategias Metacognitivas de las Escalas ACRAr (Román y Poggioli, 2013) que mide estrategias de autoconocimiento, autoplanificación y autoevaluación. Posteriormente, una vez concluida la docencia se extrajeron los registros de los estudiantes en el LMS (logs). En ellos se analizaron las siguientes categorías: accesos a la información complementaria (AIC), accesos a las orientaciones para realizar el ABP (AABP), accesos a la información sobre los conceptos teóricos (AIT), accesos al *feedback* (AIF). Además, se halló la media de visitas por día a la plataforma (MVD). Las frecuencias en estos registros determinaron distintos patrones de conducta de aprendizaje en la plataforma. También, se obtuvieron los resultados de aprendizaje de los estudiantes en los cuestionarios de autoevaluación (*quizzes*).

Análisis de datos


Se realizaron distintos análisis: 1) Regresión para lo que se aplicó un Modelo Lineal Automático y un Análisis de Regresión Lineal, 2) Análisis de correlaciones para lo que se empleó el coeficiente de correlación de Pearson, 3) Análisis de clústeres en el que se aplicó la técnica de K-means, 4) ANOVA de un factor de efectos fijos (tipo de clúster), 5) Gráficos de análisis radial, 6) Gráficos de las variables de regresión.

RESULTADOS

En primer lugar, se realizó un análisis de regresión utilizando un Modelo Lineal Automático para conocer el orden jerárquico de importancia de las conductas de aprendizaje de los estudiantes en la plataforma UBUVirtual respecto de los resultados de aprendizaje obtenidos. Se encontró en orden jerárquico de importancia, de mayor a menor, en la predicción las siguientes conductas de los estudiantes en la plataforma: la realización de las pruebas tipo test (*quizzes*), la media de visitas por día de los estudiantes (MDV), el acceso al *feedback* del docente (AIF), el uso de las estrategias metacognitivas de auto-planificación (EMP) y los accesos a la información teórica (AIT).


La selección de estas conductas conformó el patrón conductual más efectivo en este estudio. Todas estas variables explicaron el 50.8% de la varianza con relación a los resultados finales de aprendizaje de los estudiantes (ver figura 1). Asimismo, en la figura 2 se puede observar los valores de predicción sobre los valores observados.

Figura 1. Importancia del predictor en orden jerárquico sobre los resultados finales de aprendizaje



Nota. MVD=Media de Visitas por día; AIF=accesos al feedback del docente; EMP=Estrategias Metacognitivas de Planificación; AIT=Acceso a la información Teórica; Cuestionarios=quizzes

Figura 2: Valores pronosticados sobre los valores observados



Seguidamente se aplicó el coeficiente correlación de Pearson entre las variables: valores observados en los resultados finales de aprendizaje y valores predichos desde el Modelo Lineal Automático, se obtuvo un $r=.73$. Lo que indica una relación alta entre los valores observados y los predichos con esta técnica, y por lo tanto una alta fiabilidad de esta técnica en la predicción sobre los patrones conductuales más efectivos de los estudiantes en el LMS.

Posteriormente, se realizó un análisis de clústeres para lo que se utilizó el método k-means atendiendo a los resultados finales de aprendizaje obtenidos y los valores en las variables halladas como mejores predictores con el Modelo Lineal Automático. El objetivo fue el de estudiar dentro de los patrones conductuales la discriminación jerárquica de efectividad. Se hallaron tres clústeres de pertenencia (Cluster 1: considerado como medio, Cluster 2: considerado como medio-alto y Cluster 3: considerado como alto). No se interpretó ninguno de los clústeres de pertenencia como bajo, ya que los resultados finales de aprendizaje obtenidos por los estudiantes se encontraron en un intervalo de 6.08-9.73.

Las diferencias mayores entre los clústeres se hallaron en las variables MVD, AIF y en AIT. Asimismo, se encontraron diferencias significativas entre los clústeres en MVD ($F=20.96$; $p=.000$) y en AIF ($F=312.43$; $p=.000$). Todo ello, se puede consultar en la tabla 3.

Tabla 3. Centros de clústeres finales

	Clúster 1 medio $n=90$	Clúster 2 medio-alto $n=25$	Clúster 3 alto $n=6$
ETT (quizzes)	2.21	2.54	2.54
MVD	1.82	2.70	3.83
AFD	15.37	68.64	111
EMP	13	13	14
AIT	13	14	31

Nota. ETT=Resultados de aprendizaje en la realización de quizzes; MVD=Media de visitas por día; AFD=Acceso al feedback del docente; EMP=Estrategias Metacognitivas de Planificación; AIT=Acceso a la información sobre la teoría.

Atendiendo a esta clasificación seguidamente se efectuó un análisis de los patrones conductuales de aprendizaje de los estudiantes en los tres clústeres, para ello se utilizaron gráficos de análisis radial (ver figura 3, figura 4 y figura 5).

Figura 3. Patrón conductual de aprendizaje en el clúster 1




Figura 4. Patrón conductual de aprendizaje en el clúster 2


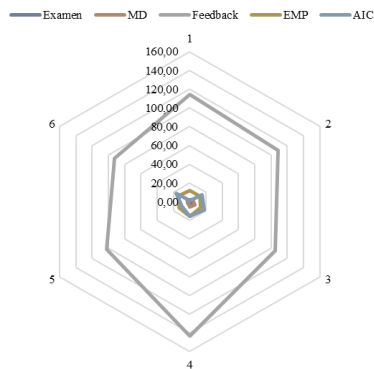


Figura 5. Patrón conductual de aprendizaje en el clúster 3



De igual modo, con el fin de estudiar el análisis conductual de los estudiantes en las variables aisladas se hallaron los gráficos de las variables de regresión (ver figura 6, figura 7, figura 8, figura 9, figura y figura10). Como puede observarse se detecta dispersión de los estudiantes especialmente en las variables MVD, AIT, AFD y en EMP respecto de la variable resultados totales de aprendizaje. Y dicha dispersión se manifiesta mayormente en dos nubes de puntos. También, se detectan *outliers* o estudiantes fuera de esas agrupaciones.

Figura 6. Valores de regresión de la variable ETT sobre la variable resultados finales de aprendizaje




Figura 7. Valores de regresión de la variable MVD sobre la variable resultados finales de aprendizaje




Figura 8. Valores de regresión de la variable AIT sobre la variable resultados finales de aprendizaje




Figura 9. Valores de regresión de la variable AFD sobre la variable resultados finales de aprendizaje





Figura 10. Valores de regresión de la variable EMP sobre la variable resultados finales de aprendizaje



Posteriormente, se realizó un Análisis de Regresión Lineal considerando las variables aisladas con el Modelo Lineal Automático sobre los resultados finales de aprendizaje. Se encontró que dichas variables explicaban el 64.1% de la varianza, siendo sobre la variable “realización de cuestionarios” en la que se encontró el mayor porcentaje de discriminación (68.5%) (ver figura 11 y figura 12).

Asimismo, la relación entre los valores pronosticados por esta técnica de predicción y los valores observados fue alta ($r=.76$). Lo que corrobora la eficacia en la predicción del patrón hallado y en especial de la variable “realización de cuestionarios”.

Figura 11. Probabilidad normal de los residuos en la variable dependiente resultados finales de aprendizaje

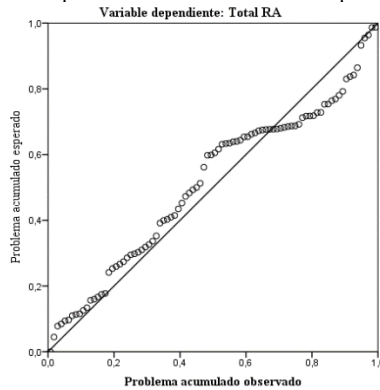
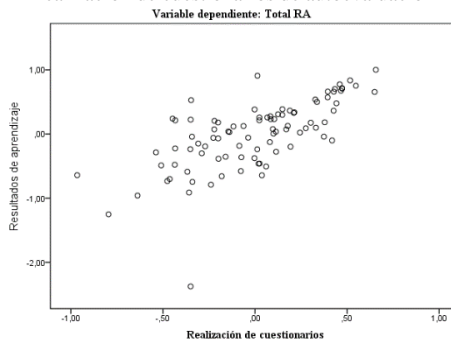


Figura 12. Regresión parcial en la variable independiente realización de cuestionarios de autoevaluación



DISCUSIÓN Y CONCLUSIONES

La aplicación de un Modelo Lineal Automático de predicción facilita la detección jerárquica en orden de prelación de las variables dependientes sobre la variable independiente. En este caso la ponderación de las variables consideradas como predictores de los resultados finales de aprendizaje. Dicha detección, permite al docente conocer el patrón conductual de aprendizaje “eficaz” vs. “no eficaz” y, además le facilita observar el orden jerárquico de efectividad de las acciones didácticas propuestas. Todo ello, le va a permitir optimizar la eficacia instruccional en los entornos de aprendizaje (Saqr et al., 2017). Asimismo, la aplicación de un Análisis de Regresión Lineal sobre las variables más efectivas facilita conocer la importancia de predicción de cada una de ellas, lo que perfila aún más el análisis tanto del proceso de aprendizaje como del producto. En este estudio se ha constatado que la interacción sistemática del estudiante en el LMS es una de las claves

para el éxito en los resultados de aprendizaje junto con la realización de pruebas de autoevaluación en dichos entornos y la consulta al *feedback* dado por el profesor a las tareas realizadas por el alumno o por el grupo de alumnos. Lo que apoya lo hallado en los estudios de Cerezo et al. (2016) y Sáiz, Marticorena, García-Osorio, y Díez-Pastor (2017).

En resumen, la utilización de técnicas de aprendizaje automático como las de regresión incrementa en el docente el conocimiento sobre el desarrollo del proceso de enseñanza-aprendizaje (Asif et al., 2017). Asimismo, facilita el descubrimiento de patrones efectivos de conductas de aprendizaje en un orden jerárquico de relevancia (Bannert, et al., 2014; Cerezo et al., 2016) y al estudiante en riesgo. Además, detecta los clústeres de patrones conductuales, más efectivos, asociados a los resultados de aprendizaje en cada contexto. En este estudio las conductas más relevantes, con un valor de predicción del 64.1%, indican que el patrón conductual más efectivo se relaciona con un estudiante planificador, reflexivo y sistemático. Por ello, si estos análisis se realizasen de forma secuencial a lo largo de periodos clave en la vida de las asignaturas (a las dos semanas, a las cuatro, a las ocho) permitirían la detección temprana de los estudiantes en riesgo y la posibilidad de realizar propuestas de mejora desde un sistema de e-orientación (Sáiz, Marticorena, y García-Osorio, 2017), en función de las variables detectadas como más exitosas y que conformarían en el patrón conductual más efectivo para cada actividad formativa. En esta línea, hay que considerar, que lo que puede resultar efectivo en un entorno, puede no serlo en otro. Para poder realizar estos estudios con fluidez, las herramientas de *Learning Analytics* de aprendizaje automático tendrían que estar incluidas en los LMS desde la inserción de un *plugin* específico (Marticorena et al., 2018). Por ello, este es un reto para las instituciones de Educación Superior, que de abordarse tendría sin duda resultados muy efectivos para el estudiante, el docente y la propia institución. Además, esta necesidad queda avalada en las propuestas de estándares europeos de calidad de la docencia plasmados en los informes de ENQA (2018) y de ANECA (2018).

A modo de síntesis y de orientación para futuros estudios, se puede concluir que el profesor tiene que realizar chequeos sistemáticos a lo largo del desarrollo de su práctica docente que le permitan detectar de la forma más temprana posible al estudiante en riesgo. Para ello, precisa partir de un modelo de patrón conductual efectivo. También, lo encontrado en este estudio puede servir de referente para el diseño de la docencia en entornos LMS. En concreto, se ha detectado que la utilización de cuestionarios de autoconocimiento junto con el *feedback* sistemático a las producciones de los estudiantes potencia la obtención de resultados de aprendizaje más eficaces (Sáiz, Marticorena, García-Osorio, y Díez-Pastor, 2017). Si bien, estas conclusiones tienen que leerse con cautela debido a las características de la muestra y al tipo de muestreo utilizado.

Por todo ello, futuras investigaciones irán dirigidas a incrementar tanto el número de la muestra como el tipo de titulaciones sobre las que se trabaje la detección de estudiantes en riesgo.

Declaración Ética

El Comité de Bioética de la Universidad de Burgos aprobó la realización de este estudio. Asimismo, se solicitó el compromiso informado por escrito de todos los participantes en este estudio.

Agradecimientos

A todos los participantes en este estudio, así como a las ayudas concedidas al GID de Universidad de Burgos B-Learning en Ciencias de la Salud: Vicerrectorado de Investigación y Transferencia del Conocimiento para la difusión de la investigación 2018 y Vicerrectorado de Personal Docente e Investigador 2018 de la Universidad de Burgos, a la difusión de los resultados de la innovación docente.

REFERENCIAS

- ANECA (2018). *Informe sobre el estado de la evaluación externa de la calidad en las universidades españolas 2017*. Documento no publicado.
- Asif, R., Merceron, A., Ali, S.A., y Haider, N.G. (2017). Analyzing undergraduate students' performance using educational data mining. *Computers y Education, 113*, 177-194. doi: 10.1016/j.compedu.2017.05.007.
- Baker, R.S., y Corbett, A.T. (2014). Assessment of robust learning with educational data mining. *Research & Practice in Assessment, 9*, 38-50.
- Bannert, M., Reimann, P., y Sonnenberg, C. (2014). Process mining techniques for analysing patterns and strategies in students; self-regulated learning. *Metacognition and Learning, 9*, 161-185. doi: 10.1007/s11409-013-9107-6.
- Bogarín, A., Cerezo, R., y Romero, C. (2017). Discovering learning processes using Inductive Miner: A case study with Learning Management Systems (LMSs). *Psicothema, 30*(3). doi: 10.7334/psicothema2018.116.
- Bouchet, F., Harley, J., Trevors, G., y Azevedo, R. (2013). Clustering and profiling students according to their interactions with an intelligent tutoring system fostering self-regulated learning. *Journal of Educational Data Mining, 5*, 104-146.
- Carbonero, M.A., Román, J.M., y Ferrer, M. (2013). Programa para “aprender estratégicamente” con estudiantes universitarios: diseño y validación experimental. *Anales de Psicología, 29*, 876-885. doi: 10.6018/analesps.29.3.165671.
- Cerezo, R., Sánchez-Santillan, 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. *Computer and Education, 96*, 42-54. doi: 10.1016/j.compedu.2016.02.006.
- ENQA (2018). Considerations for quality assurance of e-learning provision. Recuperado: <https://enqa.eu/indirme/Considerations%20for%20QA%20of%20e-learning%20provision.pdf>
- Marticorena, R., Sáiz, M.C., Arnaiz, Á., Escolar, M.C., y Queiruga, M.Á. (2018). Análisis de los resultados de aprendizaje en Ciencias de la Salud: Learning Analytics desde un plugin para Moodle. En J.J. Gázquez et al., *Intervención en contextos clínicos y de la Salud*. (Vol. II, pp.263-272). Almería: SCINFOPER.
- Román, J.M., y Poggioli, L. (2013). ACRA (r): *Escalas de estrategias de aprendizaje* [Scales of learning skills]. Caracas: Publicaciones UCAB (Postgrado: Doctorado en Educación).

- Romero, C., y Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33(1), 135-146. doi: 10.1016/j.eswa.2006.04.005.
- Sáiz, M.C. (2018), *E- Project Based Learning en Terapia Ocupacional: una aplicación en la asignatura "Estimulación Temprana*. Servicio de Publicaciones de la Universidad de Burgos, Burgos.
- Sáiz, M.C., Marticorena, R., García-Osorio, C.I. (2017). Programa individualizado de e-orientación al estudiante desde la plataforma Ubuvirtual: aplicación de Técnicas de Minería de Datos. En V. Abella, V. Ausín y V. Delgado (Eds.), *XXV Jornadas Universitarias de Tecnología Educativa: Aulas y Tecnología Educativa en evolución* (pp. 476-484). Burgos: EDTNTEC.
- Sáiz, M.C., Marticorena, R., García-Osorio, C.I., Escolar, M.C., y Queiruga, M.I. (2017). Conductas de aprendizaje en LMS: SRL y feedback efectivo en LMS. En J.C Núñez, et al. *Temas actuales de investigación en las áreas de la Salud y la Educación* (pp.747-752). Almería: SCINFOPER
- Sáiz, M.C., Marticorena, R., García-Osorio, C.I., y Díez-Pastor, J.F. (2017). How do B-Learning and Learning Patterns Influence Learning Outcomes? *Frontiers in Psychology*, 8(745), 1-13. doi: 10.3389/fpsyg.2017.00745.
- Saqr, M., Fors, U., y Tedre M. (2017). How learning analytics can early predict under-achieving students in a blended medical education course. *Med Teach*, 39(7), 757-767. doi: 10.1080/0142159X.2017.1309376
- Saeed, N., Yang, Y., y Sinnappan, S. (2009). Emerging Web Technologies in Higher Education: A Case of Incorporating Blogs, Podcasts and Social Bookmarks in a Web Programming Course based on Students' Learning Styles and Technology Preferences. *Educational Technology & Society*, 12(4), 98-109. Recuperado: <https://goo.gl/wuA1e>
- Schneider, B., y Blikstein, P. (2016). Flipping the flipped classroom: A study of the effectiveness of video lectures versus constructivist exploration using tangible user interfaces. *IEEE transactions on learning technologies*, 9(1), 5-17.
- Statistical Package for the Social Sciences (SPSS) (Versión 24). [Software de análisis estadístico de datos]. Madrid: IBM.
- Trcka, N., y Pechenizkiy, M. (2009). From local patterns to global models: Towards domain driven educational process mining. *Intelligent Systems Design and Applications, 2009. ISDA'09. Ninth International Conference on. IEEE* (pp. 1114-1119).
- Veenman, M.V.J., Bavelaar, L., De Wolf, L., y Van Haaren, M.G.P. (2014). The online assessment of metacognitive skills in a computerized learning environment. *Learning and Individual Differences*, 29, 123-130. doi: 10.1016/j.lindif.2013.01.003.

Recibido: 25 de agosto de 2018

Recepción modificaciones: 15 de septiembre de 2018

Aceptado: 17 de septiembre de 2018