



Education in the Knowledge Society

journal homepage <http://revistas.usal.es/index.php/eks/>

Ediciones Universidad
Salamanca



Influence of the Learning Trajectory on Academic Success when Using the Self Directed Based Learning Methodology

Influencia de la trayectoria de aprendizaje de la metodología Self Directed Based Learning en el éxito académico

Maria Alsina-Claret^a(*), Xavier Canaleta-Llampallas^b, Ricardo Torres-Kompen^c, Eduard De-Torres-Gómez^d, David Fonseca-Escudero^e

^a Universidad Ramon Llull, Barcelona.

<https://orcid.org/0000-0001-5525-4559>

maria.alsina@salle.url.edu

^b Universidad Ramon Llull, Barcelona.

<https://orcid.org/0000-0002-9412-8827>

xavier.canaleta@salle.url.edu

^c Universidad Ramon Llull, Barcelona.

<https://orcid.org/0000-0001-8533-5309>

ricardo.torres@salle.url.edu

^d Universidad Ramon Llull, Barcelona.

<https://orcid.org/0000-0001-9996-1941>

eduard.detorres@salle.url.edu

^e Universidad Ramon Llull, Barcelona.

<https://orcid.org/0000-0001-9471-153X>

david.fonseca@salle.url.edu

ARTICLE INFO

Keywords

Self-directed based learning, online education, learning analytics, student learning, learning trajectory, achievement motivation, achievement gain; self-instruction.

Palabras clave

self directed based learning, educación on line, análisis del aprendizaje, aprendizaje del estudiante, trayectoria de aprendizaje, motivación del rendimiento, rendimiento, autoaprendizaje.

ABSTRACT

This article presents the results of a study conducted to validate the impact of the student's behavior on their academic success in a program designed under the Self Directed Based Learning methodology. This methodology, designed for students in online graduate programs, was created in 2013 to generate a work dynamic that guides the students in their learning process. The design of this methodology seeks to increase the student's commitment to learning and improving both their progress and academic success. This study aims to identify what kind of formative activities within the student's learning trajectory determine the achievement of the learning outcomes, thus promoting the assimilation process. The analysis is based on Educational Data Mining tools applied to learning data from a graduate program; these tools analyse the formative activities associated with the student's academic success to identify any relationships between the student's activity and their academic success. These results would validate the design and construction of this methodology from the point of view of the purpose for which it was designed: to help students achieve a successful learning trajectory.

RESUMEN

Este artículo presenta los resultados de un estudio realizado con el objetivo de validar el impacto que tiene el comportamiento de un estudiante sobre su éxito académico en un programa diseñado con la metodología *Self Directed Based Learning*. Esta metodología docente, pensada para estudiantes de programas de posgrado en modalidad online, fue diseñada en 2013 con el propósito de generar una dinámica de trabajo que oriente al estudiante en su trayectoria de aprendizaje. El diseño de esta metodología busca aumentar el compromiso del estudiante con el aprendizaje, mejorando así tanto su progreso como su éxito académico. El objetivo de este estudio es identificar qué tipo de actividades formativas dentro de la trayectoria de aprendizaje del estudiante determinan la consecución de los resultados de aprendizaje propiciando así el proceso de asimilación. El análisis se basa en la aplicación de herramientas de *Educational Data*

(*) Autor de correspondencia / Corresponding author

Mining a datos de aprendizaje obtenidos de una promoción de un programa de posgrado; a través de estas herramientas, se analizan las actividades formativas que están asociadas con el éxito académico del estudiante, permitiendo así determinar la relación entre ellas. Con estos resultados sería posible validar el diseño y la construcción de esta metodología docente desde la perspectiva del propósito para el que fue diseñada: lograr que la trayectoria de aprendizaje del estudiante sea exitosa.

1. Introducción

Desde el año 2013 en La Salle Campus Barcelona (Universitat Ramon Llull) las asignaturas de los programas de posgrado en modalidad online se han diseñado siguiendo la metodología *Self Directed Based Learning* (SDBL) (Alsina et al., 2019). Esta metodología docente fue definida teniendo en cuenta los diferentes aspectos que caracterizan al estudiante de posgrado (Knowles et al., 2011; Merriam, 2001), un alumno adulto con conocimientos previos y con el objetivo de convertirse en un experto. A nivel de comportamiento se caracteriza por ser autodirigido, decidido, orientado a objetivos y responsable de su aprendizaje.

La metodología docente SDBL también tiene en cuenta los diferentes tipos de aprendizajes existentes y que dan respuesta a las características del alumno adulto (Bareiss & Radley, 2010; Broadbent & Poon, 2015; Eddy et al., 2019). Estos fueron la base para determinar la manera en cómo el alumno debía seguir su trayectoria de aprendizaje con el objetivo de adquirir los resultados de aprendizaje propuestos.

En esta metodología docente se propone una manera de aprender en la que el estudiante decide su propio ritmo de aprendizaje, además de centrarse en aquellas partes que desconoce o en las que cree que tiene más dificultades. A diferencia del aprendizaje completamente autodirigido (Silén & Uhlin, 2008), durante la trayectoria de aprendizaje el estudiante tiene a su disposición el soporte de un profesor/mentor que da soporte a la correcta adquisición de los resultados de aprendizaje de cada estudiante.

En este contexto, surge la inquietud de determinar si el diseño instruccional que se propone en la metodología docente SDBL ayuda a los estudiantes a maximizar la adquisición de los resultados de aprendizaje definidos en el programa educativo. De la misma manera, sería interesante poder identificar qué tipología de actividades son las que más se trabajan y qué relación se observa entre la realización de estas actividades y los resultados finales de cada uno de los estudiantes. Entender cuales son las actividades que influyen en la asimilación del aprendizaje es relevante para identificar aquellas que se deben evolucionar y adaptar a las nuevas herramientas digitales con impacto en el ámbito educativo, como es el caso de la inteligencia artificial generativa (García-Peñalvo, 2023, García-Peñalvo et al., 2024), pudiendo influir tanto a nivel de aprendizaje como de evaluación.

El propósito de este trabajo es el de contrastar y validar que los estudiantes que siguen la trayectoria de aprendizaje diseñada consiguen mejores resultados en su aprendizaje, relacionando las actividades realizadas por el estudiante y su éxito académico (Alkış & Temizel, 2018; Alyahyan & Düşteğör, 2020; Cohen & Baruth, 2017) bajo la metodología docente SDBL.

2. Introducción a la metodología docente SDBL

La metodología docente SDBL se basa en tres grandes componentes:

- Trayectoria de aprendizaje del alumno.
- Medida del aprendizaje del alumno.
- Acompañamiento/asesoría en la trayectoria de aprendizaje del alumno.

Este estudio se focaliza en los dos primeros bloques. El primero identifica todas las actividades que el estudiante debe realizar para poder obtener los resultados de aprendizaje que se proponen para él en cada una de las asignaturas. Una vez este ha finalizado dicha trayectoria, le sigue un segundo bloque que define las actividades que el alumno desarrolla para poder demostrar que ha adquirido los resultados de aprendizaje esperados y permite al profesor/mentor poder evaluar dichos resultados (Barberá-Gregori & Suárez-Guerrero, 2021; Cabero-Almenara & Palacios-Rodríguez, 2021).

La metodología docente SDBL define la tipología de actividades a desarrollar para asegurar la trayectoria de aprendizaje de los estudiantes, pero dado que se basa en un aprendizaje autodirigido (Artino & Stephens, 2009; Lyons & Bandura, 2020) el alumno decide si realiza todas las actividades o selecciona parte de ellas. Por este motivo, en el estudio se identifican estas actividades para poder desgranar los aspectos claves que determinan

el comportamiento del estudiante (Fariba, 2013; Lyons & Bandura, 2020) e identificar los elementos a los que los diferentes estudiantes (Chesser et al., 2020; Hazrati-Viari et al., 2012) deciden dar importancia en su proceso de estudio.

La trayectoria de aprendizaje está sustentada en la manera como se le suministran los materiales al estudiante. Todas las actividades formativas para realizar se visualizan en el Entorno Virtual de Aprendizaje (EVA) siguiendo una estructura definida, de modo que el estudiante siempre encuentra los materiales siguiendo la misma estructura en todas las asignaturas. Esta estructura es la que orienta al estudiante para que pueda seguir el orden adecuado para maximizar su rendimiento en la trayectoria de aprendizaje. Las actividades formativas para realizar por el estudiante se clasifican de la siguiente manera:

- Actividades de adquisición de conocimiento.
- Actividades de consolidación para ayudar a la asimilación del aprendizaje.

Cada unidad didáctica consta de un elemento denominado guía de aprendizaje que orienta al alumno por las diferentes actividades formativas diseñadas y los diferentes recursos docentes que se le subministran. Esta guía de aprendizaje plantea diferentes tareas/retos que el estudiante debe resolver. De la misma manera, esta guía indica al alumno los recursos docentes que debe visualizar y trabajar para poder resolver dicha tarea/reto. Para reforzar los conceptos/conocimientos aprendidos, el alumno dispone de una actividad de autoevaluación al final de cada unidad didáctica (Gros Salvat & Cano García, 2021).

De esta manera, un alumno que sigue todos los elementos diseñados para su trayectoria de aprendizaje bajo la metodología docente SDBL debería:

- Resolver todas las tareas/retos planteados en la guía de aprendizaje.
- Visualizar, leer y analizar los recursos docentes que se le suministran.
- Resolver la actividad de autoevaluación al final de cada unidad didáctica.

El diseño de la unidad didáctica implica que a su compleción el alumno ha adquirido los resultados de aprendizaje planteados y está preparado para la realización de las actividades de evaluación que permitirán al profesor/mentor hacer una valoración cuantitativa de su aprendizaje. Estas actividades se diseñan buscando la máxima adecuación a los resultados de aprendizaje que se pretenden evaluar (García-Peñalvo et al., 2020). Esta valoración, que se identificará al final con la nota de la asignatura indica en qué medida el estudiante ha alcanzado los resultados de aprendizaje propuestos.

Podemos identificar 3 tipos de actividades en la trayectoria de aprendizaje:

- Actividades de adquisición de conocimiento. Estas actividades se identifican con los recursos docentes subministrados.
- Actividades de consolidación. Estas actividades se identifican con:
 - La resolución de tareas/retos y su autocorrección por parte de los estudiantes. Estas actividades también les permiten contrastar sus resoluciones con las de sus compañeros a parte de la del profesor/mentor.
 - Las actividades de autoevaluación al final de la unidad didáctica.
- Actividades de evaluación. Estas actividades cuantifican la adquisición de los resultados de aprendizaje y son evaluadas por el profesor/mentor.

Esta trayectoria de aprendizaje diseñada en la metodología docente SDBL es la que permite que el alumno decida en qué partes o actividades dedica más esfuerzo determinando su comportamiento de aprendizaje y generando así diferentes trayectorias de aprendizaje.

3. Metodología de investigación

La metodología de investigación aplicada en este trabajo de investigación es la investigación basada en diseño (DBR) (Design-Based Research Collective, 2003; Sandoval & Bell, 2004). DBR permite poder evaluar la implementación de diseños instruccionales i entornos de aprendizaje en entornos específicos (Scott et al., 2020). Las principales fases definidas en DBR son: diseño, prueba, evaluación y reflexión.

Este estudio se centra en la fase de evaluación con el objetivo de identificar la influencia de la trayectoria aprendizaje de los alumnos en su éxito académico.

3.1. Recolección de datos

Para poder analizar la relación entre el diseño de la trayectoria de aprendizaje y el éxito académico de los alumnos en esta metodología docente, es necesario tener elementos que permitan identificar la consecución y/o compleción de los elementos de la trayectoria de aprendizaje (Križanić, 2020) para cada uno de los estudiantes, desde la privacidad y seguridad de los datos del estudiante (Amo et al., 2020, 2021). A continuación, se exponen los elementos elegidos para determinar qué ha realizado el alumno:

- Compleción de las diferentes tareas/retos. El alumno resuelve las tareas mediante la respuesta a un foro de pregunta/respuesta en el EVA.
- Compleción de los recursos docentes. Se puede identificar en el EVA si el alumno ha accedido a los diferentes recursos docentes subministrados e indicados en la guía de aprendizaje para la resolución de las tareas.
- Compleción de la actividad de autoevaluación. Se puede identificar si el alumno ha realizado esta actividad de consolidación para su aprendizaje en el EVA.

Respecto a la cuantificación del éxito académico (Giada et al., 2014), esta se identifica con la nota final de la asignatura. Esta nota es la resultante de la evaluación diseñada por el mentor/profesor basándose en las diferentes actividades de evaluación que el alumno entrega para su corrección. Estas actividades son las que se definen en el bloque Medida del Aprendizaje.

Los indicadores seleccionados para poder determinar las compleciones expuestas en el apartado anterior son los siguientes:

- Identificador del alumno.
- Ratio de tareas/retos resueltos por asignatura (#FORO_C). Esta ratio es la que indica la compleción de las tareas/retos dentro del curso analizado.
- Ratio de recursos docentes accedidos por asignatura (#REC_C). Esta ratio es la que indica la compleción de los recursos docentes dentro del curso analizado.
- Ratio de las actividades de autoevaluación hechas por asignatura (#TEST_C). Esta ratio es la que indica la compleción de las actividades finales autoevaluadas dentro del curso analizado.
- Nota final de la asignatura (NASSIG), como resultado final del sistema de evaluación diseñado por el profesor/mentor del curso.

Los datos para la realización de este estudio corresponden al Máster Universitario en Dirección de Proyectos (MUDP) en modalidad online, iniciado en octubre 2021. La promoción bajo estudio consta de 44-45 estudiantes en función de la asignatura. Para cada una de las asignaturas del programa se dispone de los datos enumerados anteriormente. El programa consta de 9 asignaturas troncales, 1 asignatura optativa y el trabajo final de máster. Para este estudio se han considerado las 9 asignaturas troncales todas ellas diseñadas siguiendo la metodología docente SDBL, ver Tabla 1.

Tabla 1. Asignaturas troncales del MUDP.

Asignatura	Código	ECTS
Gestión empresarial	MPM20	5
Gestión de costes y análisis de inversiones	MPM21	5
Gestión de proyectos	MPM23	5
Conceptos de innovación a la empresa	MPM33	5
Dirección integrada de proyectos	MPM24	5
Habilidades directivas	MPM22	5
Dirección de proyectos a la empresa	MPM25	5
Gestión de proyectos Agile	MPM35	5
Project Management Frameworks	MPM26	5

La recolección de estos datos se hace a través de los informes de compleción de actividad registrados en el EVA y del libro de calificaciones de cada uno de los cursos del programa.

3.2. Herramienta de análisis

Para poder determinar el comportamiento de los estudiantes y observar su actividad en las asignaturas es necesario poder detectar los diferentes tipos de perfiles (Amo et al., 2019), es decir, descubrir grupos de elementos en los datos, de tal manera que entre las instancias que conforman un agrupamiento sean muy similares entre sí y al mismo tiempo que las diferentes agrupaciones sean muy diferentes (Llauró et al., 2021, 2023). Para ello, se ha utilizado la herramienta ECOA (Extracción de Conocimiento Original de los Alumnos) (Canaleta et al., 2012; Canaleta & Solé, 2012) para el análisis de los datos.

ECOA permite poder analizar datos mediante métodos y herramientas que provienen del aprendizaje automático (*Machine Learning*) y concretamente se centra en la Minería de Datos Educativa o *Educational Data Mining* (EDM) (Aldowah et al., 2019; Hung et al., 2020; Romero & Ventura, 2013, 2020; Silva & Fonseca, 2017). ECOA utiliza Weka (Frank et al., 2009) como librería que provee algoritmos de aprendizaje automático. De las diferentes opciones que ofrece ECOA, este estudio se centra en el Descubrimiento de perfiles (Francis & Babu, 2019).

El método de *Data Mining* utilizado para esta funcionalidad es el de agrupamiento automático o *clustering* (Ahuja et al., 2019; Jacob et al., 2015; Navarro & Moreno-Ger, 2018). El algoritmo utilizado es el X-means. El resultado se puede visualizar en cuatro formatos diferentes:


- Formato Tabla. En este caso se obtiene la composición de los valores de cada perfil, ver Figura 1.

Figura 1. Ejemplo de tabla para Detección de perfiles.

Núm.	#FOROS_C	#TEST_C	#REC_C	NASSIG
1	8.0	9.0	10.0	8.0
2	5.0	0.0	9.0	8.0
3	0.0	1.0	2.0	1.0

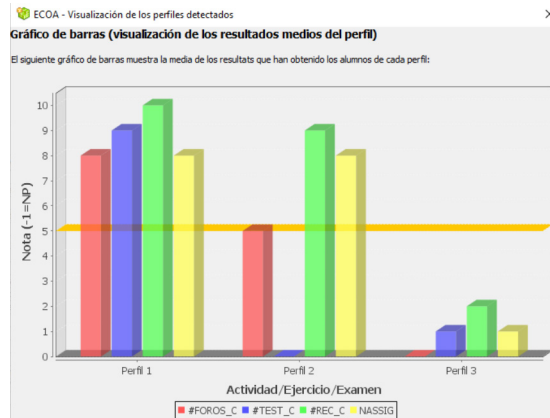
- Formato gráfico circular. En este caso visualiza la proporción de cada perfil de estudiante detectado dentro de la muestra, ver Figura 2.

Figura 2. Ejemplo de gráfico circular para detección de perfiles.



- Formato gráfico de barras (visualización de los resultados medios por perfil). En este gráfico se visualiza el valor medio de cada atributo/indicador para cada uno de los perfiles detectados, ver Figura 3.

Figura 3. Ejemplo de gráfico de barras (resultado medio por perfil) para detección de perfiles.



- Formato gráfico de barras. En este gráfico se muestra la composición porcentual de valor por cada atributo de cada uno de los perfiles, ver Figura 4.

Figura 4. Ejemplo de gráfico de barras para detección de perfiles.



3.3. Población y muestra

Los datos disponibles para el estudio consisten en los indicadores explicados en el apartado de datos. Con estos datos se procede a la detección de perfiles para cada una de las asignaturas del programa en cuestión.

Para cada una de las asignaturas del programa bajo estudio se extraen los indicadores de las actividades realizadas por el estudiante y la valoración final. Los datos recogen la información de la siguiente manera:

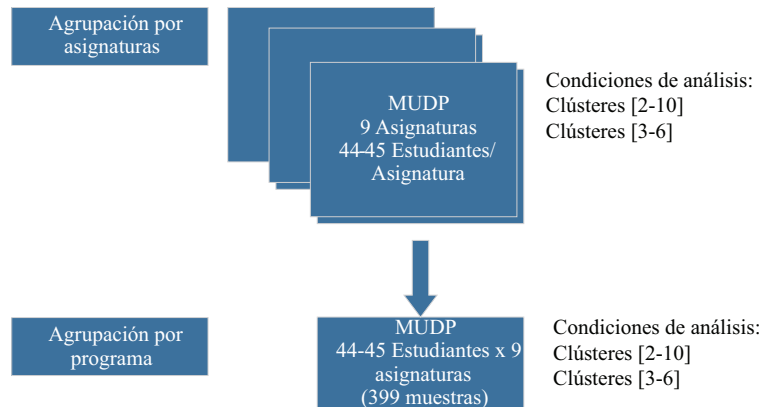
- Identificador del alumno
- Ratio de completión. Este valor se identifica con un valor de 0 a 10, indicando desde 0% de completión a 100% de completión.
 - #FORO_C: Ratio de tareas/retos resueltos por estudiante por asignatura.
 - #REC_C: Ratio de recursos docentes accedidos por estudiante por asignatura.
 - #TEST_C: Ratio de las actividades de autoevaluación realizadas por estudiante por asignatura.
- NASSIG: Nota final de la asignatura valorada entre 0 y 10. Esta nota es la resultante del promedio de las diferentes valoraciones de los trabajos destinados para la evaluación de los resultados de aprendizaje. Estas valoraciones son realizadas por el profesor/mentor de cada una de las asignaturas.

Se han analizado los resultados de la detección de perfiles en diferentes agrupaciones de datos y en diferentes condiciones de análisis para identificar los diferentes comportamientos de los estudiantes. A nivel

de agrupaciones de datos, se han considerado 9 conjuntos de datos donde el criterio de agrupación era el de asignatura, pero también se ha considerado un solo conjunto con criterio de agrupación por programa. Como resultado se han obtenido 10 conjuntos de resultados de experimentación en detección de perfiles.

Por otro lado, se han tenido en cuenta dos condiciones diferentes para el algoritmo de detección de perfiles. Inicialmente se ha indicado mínimo grupo de perfiles a detectar 2 y máximo 10 con el objetivo de tener una visión exploratoria de clústeres/perfiles. A continuación, se ha realizado el análisis forzando un mínimo grupo de clústeres/perfiles a detectar 3 y máximo 6. El objetivo en este segundo análisis es tener una visión más detallada de los diferentes comportamientos. En la Figura 5 se puede ver el esquema de los diferentes análisis planteados.

Figura 5. Esquema de los diferentes análisis para la detección de perfiles.




4. Resultados

4.1. Resultados de la agrupación por programa con clústeres [2-10]

La discusión se inicia con los resultados exploratorios de la agrupación por programa viendo cuantos perfiles se detectan y qué características tiene cada uno de ellos, ver Figura 6.

Figura 6. Resultados de la detección de perfiles por programa con clústeres [2-10].



Se puede ver en la Figura 6 tres perfiles con una distribución muy equitativa dentro del conjunto de datos con una representación de 31,8%, 34,3% y 33,8% respectivamente para perfil 1, perfil 2 y perfil 3.


A nivel de comportamiento se puede observar cómo dos de los perfiles (2 y 3) trabajan el grupo de actividad que representan los recursos docentes con un valor promedio de compleción de 9. También muestran trabajo en las actividades de consolidación, aunque el perfil 3 muestra una compleción entre 5 y 6, indicando un nivel de actividad medio, mientras que el perfil 2 se caracteriza por incluir estudiantes con un alto nivel de compleción en toda la trayectoria de aprendizaje. En los dos casos observamos un valor promedio de resultados finales en la

franja de excelente (9). Los estudiantes que no trabajan actividades de consolidación y con nivel bajo de trabajo en los recursos docente presentan valores bajos en los resultados finales.

4.2. Resultados de la agrupación por programa con clústeres [3-6]

En este caso se ha forzado la detección de mínimo 3 perfiles y máximo 6. Se pueden observar los resultados en la Figura 7.

Figura 7. Resultados de la detección de perfiles por programa con clústeres [3-6].



En este caso se detectan 5 perfiles con una distribución del 21,3%, 8,7%, 34,1%, 14,8% y 21% respectivamente, de los cuales se derivan 5 comportamientos diferenciados:

- Perfil 1 (21.3%). Perfil que se centra en los recursos docentes, consiguiendo resultados finales de media en la franja de notable.
- Perfil 2 (8.7%). Perfil que presenta una compleción de trabajo extremadamente baja, no supera la asignatura.
- Perfil 3 (34.1%). Perfil que muestra una compleción alta (9) en recursos docentes y en las actividades de consolidación, tanto de resolución de tareas/retos como de autoevaluación. En este caso, el perfil consigue unos resultados finales promedio en la franja de excelente.
- Perfil 4 (14.8%). Perfil que muestra una compleción notable (8) en los recursos docentes y una compleción alta (9) en una de las actividades de consolidación (9). En este caso este perfil se centra en la resolución de tareas/retos consiguiendo unos resultados finales promedio en la franja de excelente (9).
- Perfil 5 (21 %). Perfil que muestra una compleción alta (9) en los recursos docentes y una compleción alta (9) en una de las actividades de consolidación (9). En este caso este perfil se centra en la actividad de autoevaluación consiguiendo unos resultados finales promedio en la franja de notable (8).

En el gráfico de barras se puede observar cómo los perfiles 3, 4 y 5 se sitúan en las franjas de notable y excelente en prácticamente todos los indicadores analizados. Observando en el perfil 4 una baja actividad (<50%) en la actividad de autoevaluación y en el caso del perfil 5 en la actividad de resolución de tareas/retos.

Se puede determinar que un 69.9% de los estudiantes que trabajan actividades de consolidación consiguen mejores resultados indicando así una mayor adquisición de los resultados aprendizaje.

4.3. Resultados de la agrupación por asignatura con clústeres [2-10]

A continuación, en la Tabla 2, se pueden observar los resultados exploratorios con clústeres [2-10] para cada una de las asignaturas. Para mostrar los resultados se cambia el formato de gráfico a tabla para poder mostrar todos los resultados agrupados. En la tabla se puede ver para cada una de las asignaturas los valores numéricos de cada uno de los gráficos comentados en apartados anteriores:

- Perfiles detectados y porcentaje que representa cada uno de ellos respecto a los estudiantes totales en cada asignatura.

- Valores promedio de cada uno de los indicadores por perfil (#FORO_C, #TEST_C, #RES_C, #NASSIG)
- Composición porcentual de valores promedio de los indicadores anteriores para cada uno de los perfiles.

Tabla 2. Resultados de la detección de perfiles por asignatura con clústeres [2-10].

Asignatura	Perfiles	%	#FOROS_C	#TEST_C	#REC_C	#NASSIG	%SUSPENSO	%APROBADO	%NOTABLE	%EXCELENTE
MPM20	1	41	1.0	1.0	6.0	7.0	50	25	25	0
	2	59	4.0	9.0	9.0	8.0	25	0	25	50
MPM21	1	20.45	1.0	1.0	5.0	3.0	75	25	0	0
	2	47.73	10.0	9.0	10.0	9.0	0	0	0	100
	3	31.82	6.0	7.0	9.0	8.0	0	25	50	25
MPM23	1	35.56	9.0	1.0	8.0	8.0	25	0	50	25
	2	17.78	2.0	1.0	3.0	2.0	100	0	0	0
	3	46.67	10.0	9.0	9.0	9.0	0	0	0	100
MPM24	1	40.91	8.0	9.0	10.0	8.0	0	0	50	50
	2	43.18	5.0	0.0	9.0	8.0	25	25	25	25
	3	15.91	0.0	1.0	2.0	1.0	100	0	0	0
MPM33	1	62.79	5.0	1.0	6.0	8.0	25	50	25	0
	2	37.21	9.0	9.0	9.0	9.0	0	0	0	100
MPM35	1	31.11	6.0	0.0	6.0	7.0	25	50	25	0
	2	62.22	10.0	8.0	9.0	9.0	0	0	25	75
	3	6.67	0.0	8.0	9.0	8.0	25	0	50	25
MPM26	1	31.11	2.0	2.0	5.0	6.0	50	50	0	0
	2	40	10.0	10.0	9.0	10.0	0	0	0	100
	3	28.89	6.0	7.0	8.0	9.0	0	25	50	25
MPM22	1	18.18	1.0	0.0	4.0	5.0	75	25	0	0
	2	81.82	2.0	9.0	9.0	9.0	25	0	0	75
MPM25	1	64.44	0.0	0.0	6.0	7.0	50	25	25	0
	2	35.56	2.0	9.0	8.0	8.0	25	0	50	25

Se puede constatar como en cada asignatura los perfiles que tienen una compleción mayor en las actividades de consolidación, esto es las actividades de resolución de tareas/retos y/o las actividades de autoevaluación, obtienen mejores resultados finales en la asignatura que el resto de los perfiles.

En 6 de las 9 asignaturas (MPM21, MPM23, MPM24, MPM33, MPM35, MPM26) además se observa que los estudiantes que siguen la trayectoria de aprendizaje diseñada, resolución de las tareas/retos mediante los recursos docentes suministrados y realizan las actividades de autoevaluación, consiguen unos resultados finales de las asignaturas situados en notable y excelente (8, 9, 10). En 5 de estas 6, en la franja de excelente (9,10), mejorando el resultado obtenido por el resto de los perfiles. En el caso de la asignatura restante (MPM24) el perfil de estudiante que sigue la trayectoria de aprendizaje diseñada se sitúa en la franja de notable alto (8).

Es necesario recordar que el resultado final que se analiza es directamente la valoración cuantitativa resultante del sistema de evaluación que hace el profesor y que indica la obtención de los resultados de aprendizaje de las asignaturas analizadas.

Se procede a observar los perfiles que muestran una alta compleción en una de dos actividades de consolidación: resolución de tareas/retos o actividad de autoevaluación. Se observa este comportamiento en 8 perfiles entre las 9 asignaturas:

- 4 perfiles muestran alta compleción en la actividad de autoevaluación
- 4 perfiles muestran alta compleción en la resolución de tareas/retos

En el primer caso, 3 de los 4 perfiles se detectan en asignaturas (MPM20, MPM22 y MPM25) donde no se detecta ningún perfil que muestre comportamiento siguiendo la trayectoria de aprendizaje diseñada. En estos 3 casos, este perfil es el que obtiene máximos resultados finales de las asignaturas, mejorando el resultado del resto de perfiles. El perfil restante se observa en la asignatura MPM35. En esta, el perfil obtiene un resultado final situado en notable y menor que el resultado que muestra el perfil que sigue la trayectoria de aprendizaje completa.

En el segundo caso, los perfiles se detectan en las asignaturas MPM22, MPM24, MPM33 y MPM35 y se sitúan en resultados finales de notable. Si se observa la distribución de las compleciones de las actividades, se constata que en 3 de ellos (MPM24, MPM33 y MPM35) corresponden a valores bajos, reflejando una baja dedicación del alumno a estas actividades.

Con estos resultados se constata que de las 9 asignaturas bajo estudio:

- En 6 se detecta un perfil que sigue la trayectoria de aprendizaje diseñada obteniendo el máximo resultado final comparado con el resto de los perfiles detectados en estas asignaturas.
- En los 3 restantes, el perfil que consigue el máximo resultado final es el que muestra una alta compleción en la actividad de autoevaluación.

En la Tabla 3 se puede ver la distribución de los diferentes comportamientos discutidos en las diferentes asignaturas. En ella se indica el porcentaje de estudiantes distribuidos según:

- % AC TODO: % Estudiantes de la asignatura indicada que muestran una alta compleción en todas las actividades que componen la trayectoria de aprendizaje definida en la metodología docente SDBL.
- % AC TEST: % Estudiantes de la asignatura indicada que muestran una alta compleción en la actividad de autoevaluación.
- % AC FORO: % Estudiantes de la asignatura indicada que muestran una alta compleción en la actividad de resolución de tareas/retos.
- % AC REC: % Estudiantes de la asignatura indicada que muestran una alta compleción únicamente en el trabajo con los recursos docentes suministrados.

Tabla 3. Distribución de perfiles por comportamiento por asignatura con clústeres [2-10].

Asignatura	% AC TODO	% AC TEST	% AC FORO	% AC REC	% BC TODO
MPM20	0	59	0	41	
MPM21	79.55				20.45
MPM23	46.67		35.56		17.78
MPM24	40.91		43.18		15.91
MPM33	37.21		62.79		
MPM35	62.22	6.67	31.11		
MPM26	68.69				31.11
MPM22		81.82			18.18
MPM25		35.56		64.44	

Se observa en 4 de las asignaturas (MPM21, MPM23, MPM33, MPM26) como la mayoría (79%, 47%, 62% y 69%) de los estudiantes muestra un comportamiento que sigue la trayectoria de aprendizaje diseñada. En el caso de la MPM24 se observa como los estudiantes se dividen en dos comportamientos: aproximadamente la mitad (41%) siguiendo la trayectoria de aprendizaje diseñada y la otra mitad (43%) mostrando alta compleción en la resolución de tareas/retos. Este último se observa de manera mayoritaria (63%) en la MPM33. Mientras que en la MPM20 y en la MPM22, la mayoría de los estudiantes (59%, 82%) muestran un comportamiento con alta compleción en la actividad de autoevaluación. Finalmente, en la MPM25 se observa como la mayoría de las estudiantes (64%) se centran únicamente en los recursos docentes suministrados.

4.4. Resultados de la agrupación por asignatura con clústeres [3-6]

Para poder estudiar con más detalle los comportamientos de los estudiantes observados en los resultados anteriores, se extraen los resultados cambiando las condiciones de la detección de clústeres a mínimo 3 perfiles y máximo 6 perfiles. En Tabla 4 se pueden ver estos resultados.

Tabla 4. Resultados de la detección de perfiles por asignatura con clústeres [3-6].

Asignatura	Perfiles	%	#FOROS_C	#TEST_C	#REC_C	#NASSIG	%SUSPENSO	%APROBADO	%NOTABLE	%EXCELENTE
MPM20	1	40.91	1.0	8.0	9.0	8.0	25	0	50	25
	2	25	8.0	10.0	10.0	8.0	0	0	50	50
	3	34.09	1.0	0.0	5.0	6.0	50	50	0	0
MPM21	1	20.45	1.0	1.0	5.0	3.0	75	25	0	0
	2	56.82	9.0	9.0	10.0	9.0	0	0	0	100
	3	22.73	6.0	6.0	8.0	8.0	0	50	50	0
MPM23	1	40	8.0	2.0	8.0	8.0	25	0	75	0
	2	46.67	10.0	9.0	9.0	9.0	0	0	0	100
	3	13.33	1.0	1.0	3.0	1.0	100	0	0	0
MPM24	1	20.45	9.0	0.0	9.0	8.0	25	0	25	50
	2	22.73	1.0	0.0	8.0	8.0	50	0	50	0
	3	15.91	0.0	1.0	2.0	0.0	100	0	0	0
	4	29.55	9.0	10.0	10.0	8.0	0	0	25	75
	5	11.36	4.0	9.0	9.0	9.0	25	0	0	75
MPM33	1	34.88	8.0	0.0	8.0	9.0	25	0	50	25
	2	27.91	9.0	10.0	10.0	9.0	0	0	0	100
	3	11.63	7.0	7.0	8.0	8.0	0	0	100	0
	4	25.58	1.0	0.0	4.0	7.0	75	0	25	0
MPM35	1	22.22	9.0	0.0	7.0	9.0	25	0	25	50
	2	17.78	1.0	4.0	5.0	5.0	50	50	0	0
	3	53.33	10.0	9.0	10.0	9.0	0	0	0	100
	4	6.67	8.0	6.0	6.0	8.0	0	50	50	0
MPM26	1	35.56	3.0	2.0	4.0	6.0	75	25	0	0
	2	13.33	3.0	8.0	8.0	9.0	25	0	50	25
	3	51.11	10.0	9.0	9.0	9.0	0	0	0	100
MPM22	1	2.27	0.0	0.0	2.0	0.0	100	0	0	0
	2	4.55	0.0	0.0	0.0	0.0	100	0	0	0
	3	79.55	2.0	9.0	9.0	9.0	25	0	0	75
	4	13.64	1.0	1.0	7.0	8.0	50	0	50	0
MPM25	1	6.67	0.0	1.0	7.0	0.0	75	0	25	0
	2	4.44	0.0	0.0	0.0	0.0	100	0	0	0
	3	35.56	2.0	9.0	8.0	8.0	25	0	50	25
	4	53.33	0.0	0.0	7.0	8.0	50	0	50	0

Con estos resultados se pueden ver los mismos o más perfiles en cada una de las asignaturas. Para el análisis se seguirá el mismo proceso que en la discusión anterior: se inicia la observación de los perfiles que siguen la trayectoria de aprendizaje diseñada siguiendo por los perfiles que se centran en una de las dos actividades de consolidación.

En la Tabla 4 constatamos que en 7 de las 9 asignaturas (MPM20, MPM21, MPM23, MPM24, MPM33, MPM35, MPM26) los perfiles que siguen la trayectoria de aprendizaje diseñada con una alta compleción (notable, excelente) en los diferentes elementos que lo componen, obtienen resultados finales situados en notable y excelente. En estos casos:

- En 2 de las 7 (MPM21, MPM23), este perfil mejora el resultado final respecto al resto de perfiles detectados en estas asignaturas.
- En 4 de las 7 (MPM20, MPM33, MPM35, MPM26), este perfil comparte máximos resultados finales con otro perfil dentro de la asignatura.
- En 1 de las 7 (MPM24), este perfil se sitúa en resultado final de notable, pero sin obtener el máximo resultado final.

Se procede a observar los perfiles que muestran una alta compleción en una de dos actividades de consolidación: resolución de tareas/retos o actividad de autoevaluación. Se observa este comportamiento en 9 perfiles entre las 9 asignaturas:

- 5 perfiles muestran alta compleción en la actividad de autoevaluación
- 4 perfiles muestran alta compleción en la resolución de tareas/retos

En el primer caso:

- 2 de los 5 perfiles se detectan en MPM22 y MPM25 donde no se ha detectado perfil que siga la trayectoria de aprendizaje completa. En estas dos asignaturas este perfil es el que obtiene máximos resultados finales situados en excelente para la MPM22 y notable para la MPM25.
- Otros 2 de los 5 perfiles se detectan en MPM20 y en MPM26. En estas asignaturas estos perfiles comparten máximos resultados con el perfil que sigue la trayectoria de aprendizaje completa. En la MPM20 se sitúa en notable mientras que en la MPM26 se sitúa en excelente.
- El perfil restante de los 5 se detecta en la MPM24. En esta asignatura, este perfil es el que obtiene máximo resultados situándose en excelente y mejorando los resultados que obtiene el perfil que sigue la trayectoria de aprendizaje completa.

En el segundo caso:

- 3 de los 4 perfiles se detectan en MPM24, MPM33 y MPM35. En estas asignaturas, estos perfiles comparten resultados finales con el perfil que sigue la trayectoria de aprendizaje completa donde en 2 de ellos estos son los resultados finales más altos.
- El perfil restante se detecta en MPM23. En esta asignatura este perfil se sitúa en resultado final de notable sin ser el perfil que obtiene máximos resultados finales.

Con estos resultados se constata que de las 9 asignaturas bajo estudio:

- En 6 se detecta un perfil que sigue la trayectoria de aprendizaje diseñada y que obtiene el máximo resultado final comparado con el resto de los perfiles de la asignatura.
- En los 3 restantes, el perfil que consigue el máximo resultado final es el que muestra una alta compleción en la actividad de autoevaluación.

En la Tabla 5 se puede ver la distribución de los diferentes comportamientos discutidos en las diferentes asignaturas con las condiciones actuales de detección de perfiles: 3 perfiles mínimo y 6 perfiles máximo.

A nivel de proporción de estudiantes que muestran cada uno de los comportamientos detectados, se observa como al aumentar la cantidad de perfiles/clústeres a detectar aumentan las asignaturas con más estudiantes en el perfil con AC TODO, pasando de 4 a 6 asignaturas. En dos de ellas (MPM24 y MPM33) muy igualado con el perfil AC FORO.

Se mantiene mayoría para el perfil AC TEST en MPM20 y MPM22. También se mantiene mayoría para el perfil AC REC en la MPM25.

Tabla 5. Distribución de perfiles por comportamiento por asignatura con clústeres [3-6].

Asignatura	% AC TODO	% AC TEST	% AC FORO	% AC REC	% BC TODO
MPM20	25	40.91			34.09
MPM21	79.55				20.45
MPM23	46.67		40		13.33
MPM24	29.55	11.36	20.45	22.73	15.91
MPM33	39.54		34.88		25.58
MPM35	60		22.22		17.78
MPM26	51.11	13.33			35.56
MPM22		79.55		13.64	6.82
MPM25		35.56		60	4.44

5. Conclusiones

El estudio presentado tenía el propósito de identificar si los estudiantes que seguían la trayectoria de aprendizaje diseñada en la metodología docente SDBL conseguían mejores resultados, representado por un mayor éxito académico. En base a los resultados obtenidos para una promoción de 44/45 alumnos en el Máster Universitario de Gestión de Proyectos (MUDP) aplicando la herramienta de detección de perfiles, se puede concluir que:

- Los perfiles de estudiantes que realizan los dos tipos actividades de consolidación definidas bajo la metodología docente SDBL que determinan la trayectoria de aprendizaje definida en ella, consiguen resultados finales situados en franjas de notable y excelente, siendo más altos cuanto mayor sea la compleción de las actividades de consolidación.
- Los perfiles de estudiantes que se centran en sólo uno de los tipos de actividades de consolidación, resolución de tareas/retos o de autoevaluación, mayoritariamente consiguen resultados finales situados en las franjas de notable y excelente, pero no alcanzan máximos resultados finales.
- Los perfiles de estudiantes que mayoritariamente se centran sólo en los recursos docentes no consiguen buenos resultados finales. Se sitúan mayoritariamente en resultados justos y no aprobados.

A nivel de proporción de estudiantes que muestran cada uno de los comportamientos detectados, se puede concluir que la mayoría de los estudiantes siguen la trayectoria de aprendizaje diseñada. Dado que la metodología docente está pensada siguiendo un proceso autodirigido en su diseño, esto indica que la mayoría de los estudiantes deciden realizar las actividades propuestas. Es importante notar que uno de los objetivos de esta metodología docente era adaptarse a las características del estudiante de posgrado que muestran una alta implicación en las actividades que consideran que les aportan valor. Estos resultados confirman que la mayoría de los estudiantes dan valor a todos los elementos que conforman la trayectoria de aprendizaje propuesta mostrando más alta compleción de la actividad de autoevaluación.

Tal y como define la metodología docente SDBL, es muy importante que los estudiantes no solo trabajen con los recursos docentes que les aportan conocimiento, sino que deben trabajar también con las actividades de consolidación que les permiten poder asimilar correctamente los diferentes conceptos para mejorar así la adquisición de los resultados de aprendizaje propuestos en los programas educativos. En el estudio realizado se observa cómo desarrollar actividades de consolidación influencia en los resultados finales, es decir, éxito académico. Los estudiantes con mayor compleción en dichas actividades muestran mejores resultados finales. Se puede concluir que la trayectoria de aprendizaje definida bajo la metodología docente SDBL favorece el éxito académico de los estudiantes de este estudio.

El estudio presenta limitaciones debido a su aplicación a un único programa y a una única promoción, pero sus resultados abren posibilidades a poder reproducir este estudio a diferentes promociones de estudiantes, así como en otros programas diseñados con la metodología docente SDBL, introduciendo más indicadores que ayuden a determinar los diferentes comportamientos del estudiante en su trayectoria de aprendizaje.

Entender mejor el comportamiento del estudiante permite poder adaptar la trayectoria de aprendizaje para ayudar a mejorar el rendimiento del aprendizaje del estudiante. De esta manera se puede mejorar el diseño metodológico para que tenga una máxima adaptación a cada perfil de aprendizaje identificado.

6. Referencias

- Ahuja, R., Jha, A., Maurya, R., & Srivastava, R. (2019). Analysis of Educational Data Mining. En N. Yadav, A. Yadav, J. C. Bansal, K. Deep, & J. H. Kim (Eds.), *Harmony Search and Nature Inspired Optimization Algorithms* (Vol. 741, pp. 897-907). Springer Singapore. https://doi.org/10.1007/978-981-13-0761-4_85
- Aldowah, H., Al-Samarraie, H., & Fauzy, W. M. (2019). Educational data mining and learning analytics for 21st century higher education: A review and synthesis. *Telematics and Informatics*, 37, 13-49. <https://doi.org/10.1016/j.tele.2019.01.007>
- Alkış, N., & Temizel, T. T. (2018). The impact of motivation and personality on academic performance in online and blended learning environments. *Journal of Educational Technology & Society*, 21(3), 35-47.
- Alsina, M., Canaleta, X., Cubeles, A., & Torres, R. (2019). Self Directed Based Learning, una metodología de aprendizaje para programas no presenciales. In M. L. Sein-Echaluce Lacleta, Á. Fidalgo-Blanco, & F. J. García-Peñalvo (Eds.), *Actas del V Congreso Internacional sobre Aprendizaje, Innovación y Competitividad. CINAIC 2019 (9-11 de Octubre de 2019, Madrid, España)* (pp. 325-330). Servicio de Publicaciones Universidad de Zaragoza. <https://doi.org/10.26754/CINAIC.2019.0070>
- Alyahyan, E., & Düşteğör, D. (2020). Predicting academic success in higher education: Literature review and best practices. *International Journal of Educational Technology in Higher Education*, 17(1), 3. <https://doi.org/10.1186/s41239-020-0177-7>
- Amo, D., Alier, M., García-Peñalvo, F. J., Fonseca, D., & Casañ, M. J. (2019). Clickstream for learning analytics to assess students' behavior with Scratch. *Future Generation Computer Systems*, 93, 673-686. <https://doi.org/10.1016/j.future.2018.10.057>
- Amo, D., Prinsloo, P., Alier, M., Fonseca, D., Kompen, R. T., Canaleta, X., & Herrero-Martín, J. (2021). Local Technology to Enhance Data Privacy and Security in Educational Technology. *International Journal of Interactive Multimedia and Artificial Intelligence*, 7(2), 262-273. <https://doi.org/10.9781/ijimai.2021.11.006>
- Amo, D., Torres, R., Canaleta, X., Herrero-Martín, J., Rodríguez-Merino, C., & Fonseca, D. (2020). Seven principles to foster privacy and security in educational tools: Local Educational Data Analytics. En F. J. García-Peñalvo (Ed.), *TEEM'20 Proceedings of the Eighth International Conference on Technological Ecosystems for Enhancing Multiculturality (Salamanca, Spain, October 21st-23th, 2020)* (pp. 730-737). ACM. <https://doi.org/10.1145/3434780.3436637>
- Artino, A. R., & Stephens, J. M. (2009). Academic motivation and self-regulation: A comparative analysis of undergraduate and graduate students learning online. *The Internet and Higher Education*, 12(3-4), 146-151. <https://doi.org/10.1016/j.iheduc.2009.02.001>
- Barberá-Gregori, E., & Suárez-Guerrero, C. (2021). Evaluación de la educación digital y digitalización de la evaluación. *RIED. Revista Iberoamericana de Educación a Distancia*, 24(2), 33-40. <https://doi.org/10.5944/ried.24.2.30289>
- Bareiss, R., & Radley, M. (2010). Coaching via cognitive apprenticeship. *Proceedings of the 41st ACM Technical Symposium on Computer Science Education - SIGCSE '10* (pp. 162-166). <https://doi.org/10.1145/1734263.1734319>
- Broadbent, J., & Poon, W. L. (2015). Self-regulated learning strategies & academic achievement in online higher education learning environments: A systematic review. *The Internet and Higher Education*, 27, 1-13. <https://doi.org/10.1016/j.iheduc.2015.04.007>
- Cabero-Almenara, J., & Palacios-Rodríguez, A. (2021). La evaluación de la educación virtual: Las e-actividades. *RIED. Revista Iberoamericana de Educación a Distancia*, 24(2), 169-188. <https://doi.org/10.5944/ried.24.2.28994>
- Canaleta, X., & Solé, X. (2012). Extracción de Conocimiento Original de los Alumnos. En *VII Congreso Iberoamericano de Docencia Universitaria*, Porto.
- Canaleta, X., Solé, X., & Navarro, J. (2012). Herramienta de soporte a la evaluación del aprendizaje y la gestión docente. *Actas XVIII JENUI 2012, Ciudad Real, 10-13 de julio 2012* (pp. 359-364).
- Chesser, S., Murrah, W., & Forbes, S. A. (2020). Impact of Personality on Choice of Instructional Delivery and Students' Performance. *American Journal of Distance Education*, 34(3), 211-223. <https://doi.org/10.1080/08923647.2019.1705116>
- Cohen, A., & Baruth, O. (2017). Personality, learning, and satisfaction in fully online academic courses. *Computers in Human Behavior*, 72, 1-12. <https://doi.org/10.1016/j.chb.2017.02.030>
- The Design-Based Research Collective. (2003). Design-Based Research: An Emerging Paradigm for Educational Inquiry. (2003). *Educational Researcher*, 32(1), 5-8. <https://doi.org/10.3102/0013189X032001005>

- Eddy, P. L., Hao, Y., Markiewicz, C., & Iverson, E. (2019). Faculty Change Agents as Adult Learners: The Power of Situated Learning. *Community College Journal of Research and Practice*, 43(8), 539-555. <https://doi.org/10.1080/10668926.2018.1507848>
- Fariba, T. B. (2013). Academic Performance of Virtual Students based on their Personality Traits, Learning Styles and Psychological Well Being: A Prediction. *Procedia - Social and Behavioral Sciences*, 84, 112-116. <https://doi.org/10.1016/j.sbspro.2013.06.519>
- Francis, B. K., & Babu, S. S. (2019). Predicting Academic Performance of Students Using a Hybrid Data Mining Approach. *Journal of Medical Systems*, 43(6), 162. <https://doi.org/10.1007/s10916-019-1295-4>
- Frank, E., Hall, M., Holmes, G., Kirkby, R., Pfahringer, B., Witten, I. H., & Trigg, L. (2009). Weka-A Machine Learning Workbench for Data Mining. En O. Maimon & L. Rokach (Eds.), *Data Mining and Knowledge Discovery Handbook* (pp. 1269-1277). Springer US. https://doi.org/10.1007/978-0-387-09823-4_66
- García-Peñalvo, F. J., Corell, A., Abella-García, V., & Grande-de-Prado, M. (2020). Online Assessment in Higher Education in the Time of COVID-19. *Education in the Knowledge Society*, 21, 12. <https://doi.org/10.14201/eks.23013>
- García-Peñalvo, F. J. (2023). La percepción de la Inteligencia Artificial en contextos educativos tras el lanzamiento de ChatGPT: disrupción o pánico. *Education in the Knowledge Society*, 24, e31279. <https://doi.org/10.14201/eks.31279>
- García-Peñalvo, F. J., Llorens-Largo, F., & Vidal, J. (2024). The new reality of education in the face of advances in generative artificial intelligence. *RIED: revista iberoamericana de educación a distancia*, 27(1). <https://doi.org/10.5944/ried.27.1>
- Giada, A., Giovanni, B., & Vincenza, C. (2014). A new indicator for higher education student performance. *Higher Education*, 68(5), 653-668. <https://doi.org/10.1007/s10734-014-9737-x>
- Gros Salvat, B., & Cano García, E. (2021). Procesos de feedback para fomentar la autorregulación con soporte tecnológico en la educación superior: Revisión sistemática. *RIED. Revista Iberoamericana de Educación a Distancia*, 24(2), 107-125. <https://doi.org/10.5944/ried.24.2.28886>
- Hazrati-Viari, A., Rad, A. T., & Torabi, S. S. (2012). The effect of personality traits on academic performance: The mediating role of academic motivation. *Procedia - Social and Behavioral Sciences*, 32, 367-371. <https://doi.org/10.1016/j.sbspro.2012.01.055>
- Hung, H.-C., Liu, I.-F., Liang, C.-T., & Su, Y.-S. (2020). Applying Educational Data Mining to Explore Students' Learning Patterns in the Flipped Learning Approach for Coding Education. *Symmetry*, 12(2), 213. <https://doi.org/10.3390/sym12020213>
- Jacob, J., Jha, K., Kotak, P., & Puthran, S. (2015). Educational Data Mining techniques and their applications. *2015 International Conference on Green Computing and Internet of Things (ICGCIoT)* (pp. 1344-1348). <https://doi.org/10.1109/ICGCIoT.2015.7380675>
- Knowles, M.S., Holton III, E.F., & Swanson, R.A. (2011). *The Adult Learner* (7th ed.). Routledge. <https://doi.org/10.4324/9780080964249>
- Križanić, S. (2020). Educational data mining using cluster analysis and decision tree technique: A case study. *International Journal of Engineering Business Management*, 12. <https://doi.org/10.1177/1847979020908675>
- Llauró, A., Fonseca, D., Amo-Filva, D., Romero, S., Aláez, M., Torres Lucas, J., & Martínez Felipe, M. (2023). Academic Analytics Applied in the Study of the Relationship Between the Initial Profile of Undergraduate Students and Early Drop-Out Rates. Defining the Variables of a Predictor Instrument. En F. J. García-Peñalvo & A. García-Holgado (Eds.), *Proceedings TEEM 2022: Tenth International Conference on Technological Ecosystems for Enhancing Multiculturality* (pp. 982-990). Springer Nature. https://doi.org/10.1007/978-981-99-0942-1_103
- Llauró, A., Fonseca, D., Villegas, E., Aláez, M., & Romero, S. (2021). Educational data mining application for improving the academic tutorial sessions, and the reduction of early dropout in undergraduate students. En M. Alier & D. Fonseca (Eds.), *Proceedings TEEM'21. Ninth International Conference on Technological Ecosystems for Enhancing Multiculturality (Barcelona, Spain, October 27th - 29th, 2021)* (pp. 212-218). ACM. <https://doi.org/10.1145/3486011.3486449>
- Lyons, P., & Bandura, R. P. (2020). Stimulating employee learning: The confluence of case-based and self-regulated learning. *Industrial and Commercial Training*, 52(3), 171-183. <https://doi.org/10.1108/ICT-12-2019-0109>
- Merriam, S. B. (2001). Andragogy and Self-Directed Learning: Pillars of Adult Learning Theory. *New Directions for Adult and Continuing Education*, 2001(89), 3-14. <https://doi.org/10.1002/ace.3>
- Navarro, Á. M., & Moreno-Ger, P. (2018). Comparison of Clustering Algorithms for Learning Analytics with Educational Datasets. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(2), 9-16. <https://doi.org/10.9781/ijimai.2018.02.003>

- Romero, C., & Ventura, S. (2013). Data mining in education: Data mining in education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3(1), 12-27. <https://doi.org/10.1002/widm.1075>
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining and Knowledge Discovery*, 10(3), e1355. <https://doi.org/10.1002/widm.1355>
- Sandoval, W. A., & Bell, P. (2004). Design-Based Research Methods for Studying Learning in Context: Introduction. *Educational Psychologist*, 39(4), 199-201. https://doi.org/10.1207/s15326985ep3904_1
- Scott, E. E., Wenderoth, M. P., & Doherty, J. H. (2020). Design-Based Research: A Methodology to Extend and Enrich Biology Education Research. *CBE—Life Sciences Education*, 19(3), es11. <https://doi.org/10.1187/cbe.19-11-0245>
- Silén, C., & Uhlin, L. (2008). Self-directed learning – a learning issue for students and faculty! *Teaching in Higher Education*, 13(4), 461-475. <https://doi.org/10.1080/13562510802169756>
- Silva, C., & Fonseca, J. (2017). Educational Data Mining: A Literature Review. En Á. Rocha, M. Serrhini, & C. Felgueiras (Eds.), *Europe and MENA Cooperation Advances in Information and Communication Technologies* (Vol. 520, pp. 87-94). Springer International Publishing. https://doi.org/10.1007/978-3-319-46568-5_9