

Páginas: 363-375
Recibido: 2020-12-07
Revisado: 2021-05-07
Aceptado: 2021-05-11
Preprint: 2021-09-15
Publicación Final: 2021-09-15







www.revistascientificas.us.es/index.php/fuentes/index

DOI: <https://doi.org/10.12795/revistafuentes.2021.14278>

¿Se logra predecir el rendimiento académico? Un análisis desde la tecnología educativa

Is it possible to predict academic performance? An analysis from educational technology

  **Odiel Estrada Molina**
Universidad de las Ciencias Informáticas (Cuba)

  **Dieter Reynaldo Fuentes Cancell**
Universidad de las Ciencias Informáticas (Cuba)

Resumen

Predecir el rendimiento académico es un elemento clave en la educación, permitiéndole al profesorado diseñar acciones didácticas preventivas. Diversas disciplinas intervienen en este proceso predictivo, siendo las analíticas de aprendizaje, el aprendizaje automático, la minería de datos educativos las redes neuronales artificiales y las teorías difusas, las de mayor influencia. Se presenta una revisión sistemática a la literatura científica (2010-marzo 2020) presente en Scopus, IEEE Xplore, ACM Digital Library y Springer, con el objetivo valorar el cómo se ha comportado la predicción del rendimiento académico en dos escenarios: (1) modalidades de estudios online (en línea) y semipresencial; y (2) Apoyo tecnológico a la modalidad presencial. Se concluye el artículo con la determinación de las tendencias entre las disciplinas de las tecnologías educativas y las variables del rendimiento académico.

Abstract

Predicting academic performance is a key element in education, allowing teachers to design preventive didactic actions. Various computational disciplines are involved in this predictive process, with learning analytics, machine learning, educational data mining, artificial neural networks, and fuzzy theories being the most frequently used. A systematic review of the scientific literature (2010-March 2020) indexed in Scopus, IEEE Xplore, ACM Digital Library and Springer is presented, with the aim of evaluating how academic performance prediction has behaved in two scenarios: (1) studies online (online) and blended; and (2) technological support for the face-to-face modality. The article concludes with the determination of the trends between the disciplines of educational technologies and the variables of academic performance.

Palabras clave

Aprendizaje, educación, educación superior, estudio bibliográfico, evaluación de la educación, informática educativa, rendimiento escolar, tecnología educativa..

Keywords

Academic achievement, education, educational technology, educational computing, educational evaluation, higher education, learning, literature reviews..

1. Introducción

El rendimiento académico es una problemática actual, en cierta medida refleja la calidad del proceso de formación y su impacto en el aprendizaje. Según su naturaleza se concibe desde lo social (delimitado por las características de los contextos sociales y educativos), lo demográfico (diversidad y complejidad del alumnado)

y lo individual (dominio de conocimientos, habilidades, destrezas, etc.). En sentido general, es un indicador clave para medir el nivel de dominio del aprendizaje. Si bien el estudiantado es el máximo responsable de su aprendizaje, en el rendimiento académico intervienen factores externos (contexto escolar, familiar, social, las cualidades del profesor y los tutores, entre otros) y psicológicos (motivación, interés hacia la asignatura, etc.). Detectar a priori, los posibles estudiantes propensos a bajo rendimiento académico permitirá implementar acciones didácticas preventivas.

Predecir el rendimiento académico es una de las áreas de investigación de auge en la educación superior. Zaldumbide & Párraga (2018), declara que en el periodo 2003-2017 diversas investigaciones educativas reflejan una evolución en este sentido, empleando para ello la minería de datos educativos. El impulso de la predicción del rendimiento académico ha permitido adaptar métodos computacionales y aplicarlos a la Educación desde los fundamentos de las tecnologías educativas y la educomunicación.

Diversas disciplinas computacionales intervienen en este proceso predictivo, destacándose las analíticas de aprendizaje, el aprendizaje automático, la minería de datos educativos y las teorías difusas (Rastrollo-Guerrero, Gómez-Pulido & Durán-Domínguez, 2020). La predicción del rendimiento académico se ha analizado en diversas revisiones sistemáticas indexadas en Scopus. Shahiri, Husain & Rashid (2015), realiza un análisis (2002-inicios 2015) de las técnicas de minería de datos educativos. Del Rio & Pineda (2016), evalúan el periodo 2011-2016, coincidiendo con Shahiri, Husain y Rashid (2015), en cuanto a las técnicas de minería de datos. Na & Tasir (2017), en el periodo 2010-2016, identifican los riesgos asociados al rendimiento académico en los entornos virtuales de aprendizaje (EVA) y las técnicas de predicción. Shingari, Kumar & Khetan (2017), presenta variables para determinar la predicción del rendimiento académico y se centran en demostrar la aplicación de la minería de datos en la educación (periodo 2013-2016). Hellas, et.al., (2018), estudian 357 artículos (2010-inicios del 2018), al realizar un análisis profundo logran superar las revisiones sistemáticas publicadas anteriormente y muestra especial interés en los modelos ocultos de Markov. Zaldumbide & Párraga (2018), efectúan un mapeo sistemático de la literatura (2003-2017), enfocando su análisis en la minería de datos y los modelos predictivos. Rahul & Katarya. (2019), centran su atención en las técnicas de aprendizaje automático (periodo 2006-inicios del 2019). Ameen, Alabi & Adewole (2019), analizan el periodo 2007-inicios del 2019 y muestra una taxonomía relacionada con las variables que intervienen en el rendimiento académico. Rastrollo-Guerrero, Gómez-Pulido & Durán-Domínguez (2020), centra su análisis en las técnicas de aprendizaje supervisado y no supervisado. Cáceres, Rodríguez-García, Gómez & Rodríguez (2020), realizan una valoración de la aplicación de las analíticas de aprendizaje en la educación, identificando un grupo de investigaciones y clasificándolas según los procedimientos empleados.

Estas revisiones sistemáticas abordan la predicción del rendimiento académico, sin embargo, no identifican los tipos de investigaciones en que se sustentan los estudios primarios (experimentales y no experimentales), ni los clasifican según las modalidades de estudios (online-en línea-, presencial o semipresencial) y en pocos, se establecen la relación con las variables del rendimiento académico. Debido a las limitaciones antes mencionadas, este artículo tiene como objetivo analizar los estudios de la última década (2010-marzo 2020) relacionados con la predicción del rendimiento académico en dos escenarios: (1) modalidades de estudios online (en línea) y semipresencial; y (2) Apoyo tecnológico a la modalidad presencial. Ello contribuirá a realizar un mapeo basado en cuatro disciplinas computacionales: analíticas de aprendizaje, aprendizaje automático, minería de datos educativos, redes neuronales artificiales y, las teorías difusas.

2. Metodología

Se aplicó el protocolo PRISMA (Urrútia & Bonfill, 2010) y las anotaciones establecidas por Torres, González, Aciar & Morales (2018). Se empleó un método revisión compuesto por tres fases: Planificación (preguntas de la investigación, criterios de selección y exclusión; estrategia de búsqueda y protocolo de revisión); Conducción (evaluación y extracción de los datos por tres evaluadores) e Informe de los resultados (análisis de la validez de los estudios primarios y descripción de los datos).

Preguntas de la investigación

- Pregunta 1 (P1) ¿Cuáles son las técnicas y algoritmos que se emplean en el rendimiento académico según los escenarios: (1) modalidades de estudios online (en línea) y semipresencial y; (2) apoyo tecnológico a la modalidad presencial?
- Pregunta 2 (P2) ¿Qué variables del rendimiento académico se utilizan en correspondencia a las estrategias de investigación empleadas en los estudios primarios y según las modalidades de estudios?
- Pregunta 3 (P3) ¿Qué estrategia de investigación (experimentos o estudios de casos) predominan en los estudios primarios relacionados con el rendimiento académico?

Estrategia de búsqueda: Se realizó una búsqueda (periodo 2010-marzo 2020) en Bases de Datos y Bibliotecas especializadas (Scopus, IEEE Xplore, Springer y ACM Digital Library). La estrategia (Tabla 1) se efectuó en idioma inglés y español.

Tabla 1
Estrategia de búsqueda general

Palabras claves	
Español: Rendimiento académico, predicción, aprendizaje semipresencial, aprendizaje virtual, aprendizaje presencial.	
Inglés: academic performance, prediction, b-learning, e-learning, face-to-face learning.	
Cadena de búsqueda general	Áreas temáticas
Español (rendimiento académico AND predicción AND tecnología educativa AND recursos educativos digitales AND entorno virtual de aprendizaje AND aprendizaje semipresencial AND (aprendizaje virtual OR aprendizaje online OR aprendizaje en línea) AND aprendizaje presencial AND Educación Secundaria AND Educación Superior) Inglés (academic performance AND prediction AND educative technology AND digital educational resources AND (Virtual learning environments OR learning management system) AND B-learning AND E-learning AND Face-to-face learning AND Secondary education AND Higher education)	Rendimiento académico AND predicción del rendimiento académico AND subject_area:(“Ciencias Sociales Aplicadas” OR “multidisciplinarias” OR “educación” OR “matemática aplicada” OR “Ciencias de la Computación aplicada”) academic performance AND academic performance prediction AND subject_area:(“Applied Social Sciences” OR “multidisciplinary” OR “education” OR “applied mathematics” OR “Applied Computer Science”)

Criterios de elegibilidad y criterios de inclusión y exclusión:

- Fenómeno de interés: Predicción del rendimiento académico.
- Contexto: Educación secundaria y superior.
- Criterios de inclusión: Artículos cualitativos y cuantitativos, revisados por pares y que emplean estudios de casos (único o múltiples) o experimentos. Se incluyen artículos en revistas, revisiones sistemáticas y comunicaciones en actas de conferencias indexadas.

Existen diversidad de criterios en la metodología de la investigación científica, por lo cual, asumimos las siguientes. Metodología cualitativa (Stake, 2005) y Metodología cuantitativa (Cea d’Ancona, 2001).

- Criterios de exclusión: artículos cortos, tutoriales e investigaciones que no argumenten sus resultados.

Procedimiento de selección y validez: Se diseñó un formulario para garantizar la fiabilidad y validez. Primeramente se analizó el título, resumen y palabras claves y posteriormente, dos evaluadores analizaban los artículos; en caso de discrepancias, un tercer evaluador emitía su criterio. Para el diseño y aplicación del formulario se empleó la técnica de palabras claves «Keywording technique» (Petersen et al., 2008) y los criterios de evaluación establecidos por el Instituto de Joanna Briggs (Lockwood et al., 2015)

Extracción de datos: Se utilizó un protocolo estandarizado permitiendo la extracción de la siguiente información: referencia, autores, fecha de publicación, indexación, técnica y método de predicción, país y variables del rendimiento académico. El análisis y síntesis de los datos, se realizó mediante talleres virtuales en el Grupo de Investigación de Educación a Distancia perteneciente al Centro Nacional de Educación a Distancia, Cuba y con miembros del Grupo Computación Científica de la Universidad de las Ciencias Informáticas, Cuba.

Limitaciones: Selección del idioma español e inglés y, la búsqueda en solo cuatro bases de datos por lo cual, se obviaron investigaciones con importantes resultados publicados en otros idiomas o indexados en otras bases de datos.

3. Resultados

El análisis realizado permitió la identificación de 69 estudios primarios (Figura 1). En la siguiente URL (doi: <https://dx.doi.org/10.13140/RG.2.2.12523.57128>), se comparten los estudios de la Etapa 2.

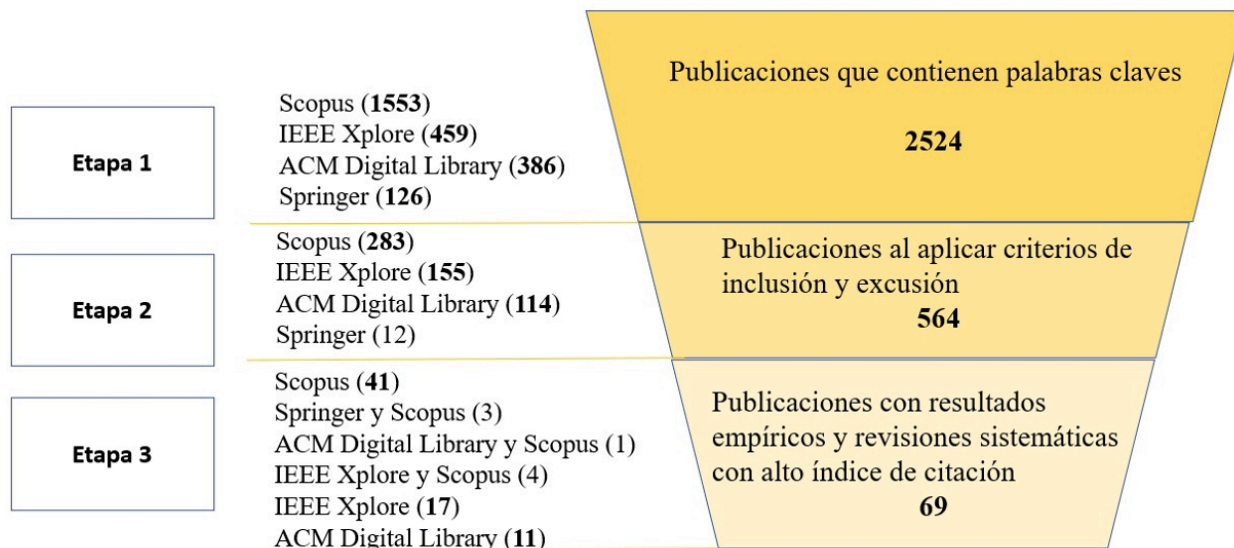


Figura 1. Síntesis del proceso de estrategia de búsqueda y del protocolo de revisión.

Las distribuciones de las publicaciones seleccionadas fueron: 2010 (1), 2011 (1), 2012 (2); 2013 (6); 2014 (5); 2015 (6), 2016(7); 2017 (8); 2018(14); 2019(12) y mayo de 2020 (7). Para responder la P1 y P2 se identificaron las disciplinas base y su relación con las variables de rendimiento académico (Tabla 2). Para profundizar en los 69 trabajos se comparten los datos obtenidos (doi: <http://dx.doi.org/10.13140/RG.2.2.12104.14085>).

Tabla 2

Relación disciplinas computacionales, técnicas, escenarios y variables

Escenario: Apoyo tecnológico a la modalidad presencial	
Disciplinas	Principales variables relacionadas con el rendimiento académico
Aprendizaje automático	Información académica, demográfica, factores psicológicos y resultado en los exámenes.
Minería de datos educativos	Información académica, demográfica y resultado en los exámenes.
Teoría difusa aplicada	Resultado en los exámenes
Analíticas de aprendizaje	(1) Temas que los grupos están discutiendo en el Chat y Estadísticas de Progreso; (2) Retroalimentación en la realización de ejercicios y test, Tiempo de interacción, Estilos de aprendizaje y, datos del EVA.
Escenario: Modalidades de estudios online (en línea) y semipresencial	
Disciplinas	Principales variables relacionadas con el rendimiento académico
Minería de datos educativos	Resultado en los exámenes e interactividad
Teoría difusa aplicada	
Aprendizaje automático	Información académica, Interactividad
Minería de datos educativos	
Analíticas de aprendizaje	(1) Temas que los grupos están discutiendo en el chat y estadísticas de progreso; (2) Retroalimentación en la realización de ejercicios y test, tiempo de interacción estudiante-sistema, estilos de aprendizaje, motivación y compromiso de aprendizaje, datos de disposiciones de aprendizaje y datos del EVA; (3) Estructura del curso y sus elementos de evaluación; estado de los alumnos; mensajes e interacciones del foro; calificaciones del estudiantado y, datos de flujo de clics.

Para responder la P3, se agruparon las publicaciones según los tipos de investigación (Tabla 3; Tabla 4; Tabla 5; Tabla 6). Se refleja que el 81.16% de las evidencias emplean estrategias basadas en estudios de casos de ellos; el 26.08% son estudios de casos múltiples y el 55.07% estudios de caso único. Lo anterior demanda en la necesidad de profundizar en investigaciones de tipo experimental.

Tabla 3
Investigaciones de tipo revisiones sistemáticas

Investigaciones	Identificador
Shahiri, Husain & Rashid (2015)	S1
Na & Tasir (2017)	S2
Hellas, et., al (2018)	S3
Amelia, Gafar & Mulyadi (2019)	S4
Rahul & Katarya (2019)	S5
Rastrolo-Guerrero, Gómez-Pulido & Durán-Domínguez (2020)	S6
Viberg, Hatakka, Bälter & Mavroudi. (2018).	S7

Tabla 4
Investigaciones que diseñan y aplican estudios de casos múltiples.

Investigaciones	Identificador
Taylan & Karagözoğlu (2010)	S8
Garcia & Mora (2011)	S9
Arsad, Buniyamin & Manan (2013)	S10
Arsad, Buniyamin & Ab Manan (2014)	S11
Bydžovská (2015)	S12
Hamsa, Indiradevi & Kizhakkethottam (2016)	S13
Adán-Coello & Tobar (2016)	S14
Dharmasaroja & Kingkaew (2016)	S15
Fedriani & Romano (2017)	S16
Ma, Yao, Ge, Pan & Guo (2017)	S17
Palominos, Díaz, Palominos & Cañete (2018)	S18
Waheed, Hassan, Aljohani, Hardman & Nawaz (2020)	S19
Herodotou, Rienties, Boroowa, Zdrahal, Hlosta & Naydenova (2017)	S20
Herodotou, Rienties, Boroowa, Zdrahal & Hlosta (2019)	S21
Rienties, Herodotou, Olney, Schencks & Boroowa (2018)	S22
Herodotou, Rienties, Verdin & Boroowa (2019)	S23
Herodotou, Rienties, Hlosta, Boroowa, Mangafa & Zdrahal (2020)	S24
Moreno-Marcos, Pong, Munoz-Merino & Delgado (2020)	S25

Tabla 5
Investigaciones que diseñan y aplican estudios de caso único.

Investigaciones	Identificador
Hasan, Palaniappan, Raziff, Mahmood & Sarker (2018)	S26
Zuviria, Mary & Kuppammal (2012)	S27
Romero, Márquez & Ventura (2012)	S28
Yildiz, Bal & Gulsecen (2013)	S29
Do & Chen (2013)	S30
Hidayah, Permanasari & Ratwastuti (2013)	S31
Jafari Petrudi, Pirouz & Pirouz (2013)	S32
Cheng & Do (2014)	S33
La Red & Podestá (2014)	S34
Mishra, Kumar & Gupta (2014)	S35
Yadav, Soni & Pal (2014)	S36
Akçapınar, Altun & Aşkar (2015)	S37
La Red Martínez, Karanik, Giovannini & Pinto (2015)	S38
Li, Shang & Shen (2016)	S39
Merchan-Rubiano & Duarte-Garcia (2016)	S40

Continued on next page

Table 5 continued

Pandey & Taruna (2016)	S41
Pardo, Mirriahi, Martinez-Maldonado, Jovanovic, Dawson & Gašević (2016)	S42
Zambrano, Urrutia & Varas (2017)	S43
Cuji, Gavilanes & Sánchez (2017)	S44
Jembere, Rawatlal & Pillay (2017)	S45
Tanabe, Kagari, Kitanaka, Takeuchi & Hirokawa (2017)	S46
Shanthini, Vinodhin & Chandrasekaran (2018)	S47
Amoo, Alaba & Usman (2018)	S48
Adil, Tahir & Maqsood (2018)	S49
Benablo, Sarte, Dormido & Palaoag (2018)	S50
Hirokawa (2018)	S51
Maitra, Madan & Mahajan (2018)	S52
Salam, Paul, Tabassum, Mahmud, Ullah, Rahman & Rahman (2018)	S53
Son & Fujita (2018)	S54
Chango, Cerezo & Romero (2019)	S55
De-La-Hoz, De-La-Hoz & Fontalvo (2019)	S56
Altaf, Soomro & Rawi (2019)	S57
Matcha, Gašević, Uzir, Jovanović & Pardo (2019)	S58
Meca, Mollá-Campello & Rabasa(2019)	S59
Maitra, Eshrak, Bari, Al-Sakin, Hossain, Akter & Haque (2019).	S60
Martinez-Rodriguez, Alvarez-Xochihua, Mejia Victoria, Jordan Aramburo & Gonzalez-Fraga (2019)	S61
Van Leeuwen, Janssen, Erkens & Brekelmans (2015)	S62
Gutiérrez, Seipp, Ochoa, Chiluiza, Laet & Verbert (2018)	S63

Tabla 6

Investigaciones que diseñan y aplican experimentos.

Investigaciones	Identificador
Musso, Kyndt, Cascallar & Dochy (2013)	S64
Popescu & Leon (2018)	S65
Yao, Lian, Cao, Wu & Zhou (2019)	S66
Castrillón, Sarache & Ruiz-Herrera (2020)	S67
Hai-tao, et.al., (2020)	S68
Tempelaar, Rienties & Giesbers (2015)	S69

Se identificaron las disciplinas base según los escenarios (Figura 2) y los tipos de investigación (Figura 3). Estos resultados muestran la efectividad de la aplicación de las cinco disciplinas que se referencian además, se resaltan los siguientes aspectos: (1) una mayor representatividad de estudios de casos sobre los estudios experimentales; (2) la posible relación entre un bajo engagement y el rendimiento académico «con énfasis en la modalidad de estudios online (en línea) y semipresencial»; (3) para analizar factores psicológicos tales como: motivación, compromiso, engagement, y actitudes, el método de análisis de regresión es el más recomendado; y (4) en cuanto a la predicción en sí, hay una tendencia a emplear los árboles de decisión y el perceptrón multicapa.

Escenario: Apoyo tecnológico a la modalidad presencial
<ul style="list-style-type: none"> • Analítica de aprendizaje (S7;S21;S22;S62;S63;S68) • Aprendizaje automático (S1,S5,S6,S19,S41,S44,S50,S51,S54,S59,S61,S66) • Minería de datos educativa (S2,S3,S9,S12,S14,S28,S34,S35,S38,S40,S42,S45,S55,S58,S60) • Red neuronal artificial (S10,S11,S15,S57,S64) • Teorías difusas aplicadas (S4,S8,S13,S16,S18,S27,S30,S31,S32,S33,S36,S39,S43,S49,S52,S53,S54)
Escenario: Modalidades de estudios online (en línea) y semipresencial
<ul style="list-style-type: none"> • Analítica de aprendizaje (S20;S23;S24;S25;S46,S69) • Aprendizaje automático (S17,S47,S56) • Minería de datos educativa (S37,S26,S65) • Red neuronal artificial (S48) • Teorías difusas aplicadas (S29)

Figura 2. Clasificación de disciplinas según los escenarios.

Escenario: Apoyo tecnológico a la modalidad presencial	Escenario: Modalidades de estudios online (en línea) y semipresencial
<p style="text-align: center;">Analítica de aprendizaje</p> Estudios de casos únicos: 2 Estudios de casos múltiples: 2 Experimentos controlados: 1	<p style="text-align: center;">Analítica de aprendizaje</p> Estudios de casos únicos: 1 Estudios de casos múltiples: 4 Experimentos controlados: 1
<p style="text-align: center;">Aprendizaje automático</p> Estudios de casos únicos: 5 Estudios de casos múltiples: 2 Experimentos controlados: 2	<p style="text-align: center;">Aprendizaje automático</p> Estudios de casos únicos: 2 Estudios de casos múltiples: 1 Experimentos controlados: -
<p style="text-align: center;">Minería de datos educativa</p> Estudios de casos únicos: 10 Estudios de casos múltiples: 3 Experimentos controlados: -	<p style="text-align: center;">Minería de datos educativa</p> Estudios de casos únicos: 2 Estudios de casos múltiples: - Experimentos controlados: 1
<p style="text-align: center;">Red neuronal artificial</p> Estudios de casos únicos: 1 Estudios de casos múltiples: 3 Experimentos controlados: 1	<p style="text-align: center;">Red neuronal artificial</p> Estudios de casos únicos: 1 Estudios de casos múltiples: - Experimentos controlados: -
<p style="text-align: center;">Teorías difusas aplicadas</p> Estudios de casos únicos: 11 Estudios de casos múltiples: 5 Experimentos controlados: -	<p style="text-align: center;">Teorías difusas aplicadas</p> Estudios de casos únicos: 1 Estudios de casos múltiples: - Experimentos controlados: -



Figura 3. Tipo de investigación y tipo de métodos según los escenarios.

4. Discusión

En la revisión sistemática se detectó como regularidades que, en la disciplina: Teorías difusas aplicadas, se destacan las técnicas neuro-difusas. Estas aceptan múltiples entradas con varias reglas que pueden aplicarse en múltiples capas, es decir permite relacionar redes neuronales artificiales y la lógica difusa. Para lograr una correcta modelación difusa lingüística se identifican el objetivo y la información a manipular, proceso que es centrado en interpretabilidad o en exactitud, siendo la principal entrada las calificaciones de los estudiantes.

En cuanto a las Disciplinas: Minería de datos educativos y redes neuronales artificiales, se evidencia una tendencia al uso de la técnica de K vecino más cercano y a la integración de las técnicas de árboles de decisión, análisis de la regresión y el algoritmo Naïve Bayes. La técnica de K vecino más cercano, empleada por los autores tiene como particularidad que, al aplicar el algoritmo regresión del Gran margen de vecino más cercano (LMNMR, siglas en inglés) se basa en la extensión (Leon & Popescu, 2017) de las funciones objetivos finales. El LMNMR se emplea para determinar la predicción del rendimiento del alumno en función de su interacción e interactividad en los blogs, herramientas de microblogging y actividades de colaboración. Las herramientas más empleadas son: DataShop, GISMO, Meerkat-ED y MDM Tool. De conjunto con la minería de datos, se potencia el empleo de la red neuronal artificial, que si bien no es frecuente en los estudios analizados, se refleja el uso de una red neuronal prealimentada o el clásico Perceptrón multicapa -red con alimentación hacia delante-.

En la Disciplina de Aprendizaje automático, por tendencia «en dependencia del escenario educativo», se pueden utilizar tres modelos: (1) Modelos de transporte, el proceso al ser predecible (al estudiante no se le provee diferentes rutas de aprendizaje) se emplean matrices de tiempo-tarea y la secuencia del tiempo será principalmente término por término; (2) Modelos basado en árboles (contienen nodos de decisión críticos pero se mantiene la linealidad en los puntos inicial y final), dirigido fundamentalmente cuando el estudiante desconoce que alternativas de rutas de aprendizaje escoger; y (3) los modelos complejos, se emplean para procesos de aprendizaje impredecibles. Se utilizan como tendencia las técnicas: (1) algoritmo k-means de conjunto con el agrupamiento que realiza el software RapidMiner y el índice de Davies-Bouldin (DB) para validar el agrupamiento interno; (2) Máquinas de vectores de soporte, algoritmo Naïve Bayes, Regresión lógica, Bosques Aleatorios y el Extreme Gradient Boosting; y (3) Aprendizaje profundo memoria a largo plazo.

Por ultimo en la Disciplina Analíticas de aprendizaje, se reflejan como tendencias: (1) las herramientas LOCO Analyst, GISMO, openDLAs (basada en la analítica descriptiva), edX-MAS+ (basada en la analítica predictiva), edX-WS: Warning System (basadas en la analítica prescriptiva); edXFAS: Feedback Analysis System (basadas en la analítica prescriptiva) y Student System Success, y (2) incluir dentro del estudio clásico del desempeño estudiantil asincrónico, lo relacionado con el registro y análisis de datos que permita determinar competencias asociadas al trabajo grupal y la gestión eficaz del tiempo. La calidad de las predicciones se mide por precisión, recuerdo y medida. La precisión es el porcentaje de estudiantes identificados correctamente en la predicción (en riesgo). Recordar es el porcentaje de estudiantes que están en riesgo según la predicción identificada. La medida F es la media armónica de precisión y recuperación que generalmente se usa para proporcionar el rendimiento del modelo de clasificación utilizando una medida. Se evidencia en las analíticas de aprendizaje, el empleo de modelos de agrupación en clústeres. Los estudios a gran escala evidencian un marcado empleo de las herramientas Student Probability Model (SPM) y OU Analyse (OUA). Los SPM se basan en modelos generados a través de regresiones logísticas de un conjunto de variables explicativas agrupadas en, Factores estudiantiles, Curso de estudiante, Progreso previo en la universidad y, Variables de curso y calificación. El OUA emplea tres métodos de aprendizaje automático: (1) clasificador Naïve Bayes (NB), (2) Árbol de clasificación y regresión (CART) y (3) k Vecinos más cercanos (k-NN). Por tendencia se refleja que en los cursos abiertos masivos en línea (MOOCs por sus siglas en inglés), considerar las siguientes variables de entrada: (1) estructura del curso y sus elementos de evaluación; (2) estado de los alumnos en cada componente del curso; (3) mensajes e interacciones del foro; (4) calificaciones del estudiantado en cada actividad evaluada y por cada asignatura; y (5) datos de flujo de clics.

Los resultados obtenidos en esta revisión permitieron sintetizar en los siguientes escenarios, la relación entre las variables pertenecientes a la educación y a la predicción del rendimiento académico:

- Escenario: apoyo tecnológico a la modalidad presencial, se destacan las siguientes relaciones: aprendizaje automático-información académica, demográfica, factores psicológicos y resultados docentes (Rahul y Katarya, 2019; Rastrollo-Guerrero, Gómez-Pulido y Durán-Domínguez, 2020); (2) minería de datos educativos-información académica, demográfica y resultado en los exámenes (Na y Tasir, 2017; Hellas, et., al, 2018); (3) teoría difusa aplicada-resultado en los exámenes (Meca, Mollá-Campello y Rabasa, 2019); y (4) las analíticas de aprendizaje con los temas discutidos en el Chat, estadísticas de progreso, retroalimentación de ejercicios y, tiempo de interacción (Rienties, Herodotou, Olney, Schencks y Boroowa, 2018; Herodotou, Rienties, Boroowa, Zdrahal y Hlosta, 2019)

- Escenario: modalidades de estudios online (en línea) y semipresencial, las relaciones entre disciplinas computacionales-variables del rendimiento académico son: (1) minería de datos educativos-resultado en los exámenes, información académica e interactividad (Hasan, Palaniappan, Raziff, Mahmood y Sarker, 2018; Popescu y Leon, 2018); (2) la teoría difusa aplicada (Yildiz, Bal y Gulsecen, 2013) y el aprendizaje automático (Shanthini, Vinodhin y Chandrasekaran, 2018) ambas relacionadas con los exámenes y la interactividad mientras que, las analíticas de aprendizaje están relacionadas con: (1) temas que los grupos están discutiendo en el chat y estadísticas de progreso, (2) retroalimentación en la realización de ejercicios, tiempo de interacción estudiante-sistema, estilos de aprendizaje, motivación, datos de disposiciones de aprendizaje y datos del sistema de gestión del aprendizaje y, (3) estructura del curso; estado de los alumnos en cada componente del curso; interacciones del foro; calificaciones y datos de flujo de clics.

El uso de la lógica difusa en la evaluación del rendimiento académico permite detectar a priori posibles dificultades de aprendizaje sin embargo, depende de la base de conocimientos, las reglas diseñadas y, los fundamentos psicopedagógicos en las cuales se sustentan (Amelia, Gafar & Mulyadi, 2019). Otro de los resultados obtenidos que coinciden con estudios previos, es lo relacionado con el uso de estrategias de minerías de datos basadas en los algoritmos genéticos difusos, las redes neuronales y los árboles de decisión (Rahul & Katarya, 2019; Hamsa, Indiradevi & Kizhakkethottam, 2016) sin embargo, sigue siendo latente las pedagogías emergentes que orienten el cómo interpretar los resultados de la predicción y la intervención pedagógica.

5. Conclusiones

El artículo presenta una revisión sistemática de la predicción del rendimiento académico desde la tecnología educativa. Las técnicas y algoritmos que más se emplean en esta predicción son: las analíticas de aprendizaje, aprendizaje automático, minería de datos educativos, redes neuronales artificiales y, las teorías difusas.

Las estrategias de investigación que predominan en los estudios primarios analizados son los estudios de caso único y los estudios de casos múltiples. Lo anterior refleja la necesidad de potenciar el empleo de experimentos controlados para determinar objetivamente la predicción del rendimiento académico.

En el escenario de “modalidades de estudios online (en línea) y semipresencial”, hay una preponderancia a emplear analíticas de aprendizaje, el aprendizaje automático y la minería de datos educativos; sin embargo en el segundo escenario “apoyo tecnológico a la modalidad presencial”, se emplean en mayor medida las teorías difusas aplicadas; la minería de datos educativos y el aprendizaje automático.

Se considera que sí hay evidencias que apoyan la predicción del rendimiento académico, aun así, desde una perspectiva de la sociología de la educación y desde la psicopedagogía, aun es insuficiente la inclusión de variables tales como: factores del alumnado (salud física, actitudinal y afectivo), factores casuales (contexto familiar, escolar y social) y el autocontrol (Mendoza-Macías y Barcia-Briones, 2020).

¿Se logra predecir el rendimiento académico? Respondemos que sí, sin embargo a modo de cierre deseamos aclarar que, en el Escenario: Modalidades de estudios online (en línea) y semipresencial, se destacan cinco variables (Tabla 2), sin embargo es interesante que aun cuando los investigadores declaran obtener más del 85% de efectividad, los resultados no son del todo predictivos al declararse por tendencia la necesidad de investigar la relación entre las variables. En este sentido, se concuerda con los resultados (Quinn & Gray, 2020), que aun cuando los estudiantes mantienen una alta motivación, interacción e interactividad, pueden obtener un rendimiento inadecuado. Por otro lado, en el Escenario: Apoyo tecnológico a la modalidad presencial, se destacan el empleo de variables agrupadas en demográficos, socioeconómicos y, académicos. Los primeros, relacionados fundamentalmente a la edad y el sexo, sin embargo es casi nulo la inclusión de los criterios del estado civil y el status migratorio. Los segundos, asociados a la solvencia económica de los padres, sin embargo es carente la inclusión del criterio trabajo laboral realizado por el estudiante. Por último, lo factores académicos, que integran la motivación profesional, las calificaciones de los exámenes y el recorrido cognitivo previo del estudiante, sin incluir criterios asociados a la autoeficacia. Estas carencias en criterios establecidos en el rendimiento académico, son coherentes con investigaciones psicopedagógicas (Fernández-Mellizo & Constante-Amores, 2020) por lo cual se convierten en proyecciones para el trabajo futuro. Desde nuestra perspectiva, las investigaciones analizadas se limitan a solo presentar los resultados de la predicción del rendimiento académico, sin explicar que estrategias se proponen para mitigar o mejorar este rendimiento. Por tal motivo, se sugiere como trabajo futuro que, al realizar y publicar una investigación relacionada con la predicción del rendimiento académico, se respondan además pregunta tales como ¿Cuáles acciones pedagógicas son las más adecuadas en relación a los resultados obtenidos en la predicción del rendimiento académico?, ¿cuáles son los resultados de aplicar estas acciones pedagógicas? Por tanto, se considera que, investigar en la predicción del rendimiento académico implica además el cómo intervenir

pedagógicamente en el aprendizaje del estudiante y valorar los resultados obtenidos.

Referencias

- Adán-Coello, J. M., y Tobar, C. M. (2016). Using Collaborative Filtering Algorithms for Predicting Student Performance. *Lecture Notes in Computer Science*, 9831 LNCS, 206-218. https://doi.org/10.1007/978-3-319-44159-7_15
- Adil, M., Tahir, F., y Maqsood, S. (2018). Predictive Analysis for Student Retention by Using Neuro-Fuzzy Algorithm. In *10th Computer Science and Electronic Engineering (CEECE)* (p. 41-45).
- Akçapınar, G., Altun, A., y Aşkar, P. (2015). Modeling Students' Academic Performance Based on Their Interactions in an Online Learning Environment. *Elementary Education Online*(3), 14-14. <https://doi.org/10.17051/ie.2015.03160>
- Altaf, S., Soomro, W., y Rawi, M. I. M. (2019). Student Performance Prediction using Multi-Layers Artificial Neural Networks. In *En 2019 3rd International Conference on Information System and Data Mining-ICISDM 2019* (p. 59-64).
- Ameen, A., Alabi, M., y Adewole, K. (2019). Students' academic performance and dropout prediction: A review. *Malaysian Journal of Computing*, 4(2), 278-303. <https://doi.org/10.24191/mjoc.v4i2.6701>
- Amelia, N., Gafar, A., y Mulyadi, Y. (2019). Meta-analysis of student performance assessment using fuzzy logic. *Indonesian Journal of Science and Technology (IJoST)*, 4(1), 74-88. <https://doi.org/10.17509/ijost.v4i1.15804>
- Amoo, M. A., Alaba, O. B., y Usman, O. L. (2018). Predictive modelling and analysis of academic performance of secondary school students: Artificial Neural Network approach. *International Journal of Science and Technology Education Research*, 9(1), 1-8. <https://doi.org/10.5897/ijster2017.0415>
- ancona, M. A. C. D. (2001). *Metodología cuantitativa. Estrategias y técnicas de investigación social*. Madrid, Síntesis.
- Arsad, P. M., Buniyamin, N., y Manan, J. A. (2013). A neural network students' performance prediction model (NNSPPM). *IEEE International Conference on Smart Instrumentation*.
- Arsad, P. M., Buniyamin, N., y Manan, J. A. (2014). Neural Network and Linear Regression methods for prediction of students' academic achievement. *IEEE Global Engineering Education Conference (EDUCON)*, 916-921.
- Benablo, C. I. P., Sarte, E. T., Dormido, J. M. D., y Palaoag, T. (2018). Higher Education Student's Academic Performance Analysis through Predictive Analytics. *En 2018 7th International Conference on Software and Computer Applications - ICSCA 2018*, 238-242.
- Borgobello, A., y Roselli, N. (2016). Rendimiento académico e interacción sociocognitiva de estudiantes en un entorno virtual. *Educação E Pesquisa*, 42(2), 359-374. <https://doi.org/10.1590/S1517-9702201606143478>
- Bydžovská, H. (2015). Student Performance Prediction Using Collaborative Filtering Methods. *Artificial Intelligence in Education*, 550-553. https://doi.org/10.1007/978-3-319-19773-9_59
- Cáceres, P., Rodríguez-García, A. M., Gómez, G., y Rodríguez, C. (2020). Learning analytics in higher education: a review of impact scientific literature. *IJERI: International Journal of Educational Research and Innovation*(13), 32-46. <https://doi.org/10.46661/ijeri.4584>
- Castrillón, O., Sarache, W., y Ruiz-Herrera, S. (2020). Predicción del rendimiento académico por medio de técnicas de inteligencia artificial. *Formación universitaria*, 13(1), 93-102. <http://dx.doi.org/10.4067/S0718-50062020000100093>
- Chango, W., Cerezo, R., y Romero, C. (2019). Predicting academic performance of university students from multi-sources data in blended learning. *En Second International Conference on Data Science, E-Learning and Information Systems - DATA '19*.
- Cheng, J. J., y Do, H. (2014). A cooperative Cuckoo Search - hierarchical adaptive neuro-fuzzy inference system approach for predicting student academic performance. *Journal of Intelligent y Fuzzy Systems*, 27, 2551-2561. <https://doi.org/10.3233/IFS-141229>
- Cuji, B., Gavilanes, W., y Sánchez. (2017). Modelo predictivo de deserción estudiantil basado en arboles de decisión. *Revista Espacios*, 38(55), 1-27.
- De-La-Hoz, E., De-La-Hoz, E., y Fontalvo, T. (2019). Metodología de Aprendizaje Automático para la Clasificación y Predicción de Usuarios en Ambientes Virtuales de Educación. *Información tecnológica*, 30(1), 247-254. <https://dx.doi.org/10.4067/S0718-07642019000100247>
- Dharmasaroja, P., y Kingkaew, N. (2016). Application of artificial neural networks for prediction of learning performances. In *En 2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)* (p. 745-751).
- Do, Q. H., y Chen, J. F. (2013). A Neuro-Fuzzy Approach in the Classification of Students' Academic Performance. *Computational Intelligence and Neuroscience*, 1-7. <https://doi.org/10.1155/2013/179097>
- Fedriani, E., y Romano, I. (2017). Fuzzy-Set Qualitative Comparative Analysis to Determine Effects from

- Socio-Economical Factors and University Students Performance. *Revista De Métodos Cuantitativos Para La Economía Y La Empresa*, 24, 250-269.
- Fernández-Mellizo, M., y Constante-Amores, A. (2020). Determinantes del rendimiento académico de los estudiantes de nuevo acceso a la Universidad Complutense de Madrid. *Revista de educación*, 387, 213-231. <https://doi.org/10.4438/1988-592X-RE-2020-387-433>
- García, E. P. I., y Mora, P. M. (2011). Model Prediction of Academic Performance for First Year Students. In *10th Mexican International Conference on Artificial Intelligence* (p. 169-174).
- García-Martín, S., y Cantón-Mayo, I. (2019). Use of technologies and academic performance in adolescent students. *Comunicar*, 59, 73-81. <https://doi.org/10.3916/C59-2019-07>
- Gutiérrez, F., Seipp, K., Ochoa, X., Chiluíza, K., Laet, T. D., y Verbert, K. (2020). LADA: A learning analytics dashboard for academic advising. *Computers in Human Behavior*, 107, 1-13. <https://doi.org/10.1016/j.chb.2018.12.004>
- Hai-Tao, P., Ming-Qu, F., Hong-Bin, Z., Bi-Zhen, Y., Jin-Jiao, L., Chun-Fang, L., Yan-Ze, Z., y Rui, S. (2020). Predicting academic performance of students in Chinese-foreign cooperation in running schools with graph convolutional network. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-020-05045-9>
- Halpern, D., Piña, M., y Ortega-Gunckel, C. (2020). School performance: New multimedia resources versus traditional notes. *Comunicar*, 64, 39-48. <https://doi.org/10.3916/C64-2020-04>
- Hamsa, H., Indiradevi, S., y Kizhakkethottam, J. J. (2016). Student Academic Performance Prediction Model Using Decision Tree and Fuzzy Genetic Algorithm. *Procedia Technology*, 25, 326-332. <https://doi.org/10.1016/j.protcy.2016.08.114>
- Hasan, R., Palaniappan, S., Raziff, A. R. A., Mahmood, S., y Sarker, K. U. (2018). Student Academic Performance Prediction by using Decision Tree Algorithm. In *En 2018 4th International Conference on Computer and Information Sciences (ICCOINS)* (p. 1-5).
- Hellas, A., Liao, S. N., Ithantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., Knutas, A., Leinonen, J., Messom, C., y Liao, S. (2018). Predicting academic performance: a systematic literature review. *Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education - ITiCSE*, 175-199.
- Herodotou, C., Rienties, B., Boroowa, A., Zdrahal, Z., y Hlosta, M. (2019). A large-scale implementation of predictive learning analytics in higher education: the teachers' role and perspective. *Educational Technology Research and Development*. <https://doi.org/10.1007/s11423-019-09685-0>
- Herodotou, C., Rienties, B., Boroowa, A., Zdrahal, Z., Hlosta, M., y Naydenova, G. (2017). *Implementing predictive learning analytics on a large scale: The teacher's perspective*. En *Seventh International learning analytics y knowledge conference*. Vancouver, British Columbia.
- Herodotou, C., Rienties, B., Hlosta, M., Boroowa, A., Mangafa, C., y Zdrahal, Z. (2020). The scalable implementation of predictive learning analytics at a distance learning university: Insights from a longitudinal case study. *The Internet and Higher Education*, 45, 100725. <https://doi.org/10.1016/j.iheduc.2020.100725>
- Herodotou, C., Rienties, B., Verdin, B., y Boroowa, A. (2019). Predictive learning analytics 'at scale': Guidelines to successful implementation in higher education. *Journal of Learning Analytics*, 6(1), 85-95. <https://doi.org/10.18608/jla.2019.61.5>
- Hidayah, I., Permanasari, A. E., y Ratwastuti, N. (2013). Student classification for academic performance prediction using neuro fuzzy in a conventional classroom. In *En 2013 International Conference on Information Technology and Electrical Engineering (ICITEE)*.
- Hirokawa, S. (2018). Key attribute for predicting student academic performance. In *En 10th International Conference on Education Technology and Computers - ICETC '18* (p. 308-313).
- Jembere, E., Rawatlal, R., y Pillay, A. W. (2017). Matrix Factorisation for Predicting Student Performance. In *7th World Engineering Education Forum (WEEF)* (p. 513-518).
- La-Red, D. L., y Podestá, C. E. (2014). Metodología de Estudio del Rendimiento Académico Mediante la Minería de Datos. *Campus virtuales*, 3(1), 56-73. Retrieved from <http://www.uajournals.com/campusvirtuales/journal/4/5.pdf>
- Leeuwen, A. V., Janssen, J., Erkens, G., y Brekelmans, M. (2015). Teacher regulation of cognitive activities during student collaboration: Effects of learning analytics. *Computers y Education*, 90, 80-94. <https://doi.org/10.1016/j.compedu.2015.09.006>
- Leon, F., y Popescu, E. (2017). Using Large Margin Nearest Neighbor Regression Algorithm to Predict Student Grades Based on Social Media Traces. *Advances in Intelligent Systems and Computing*, 617.
- Li, Z., Shang, C., y Shen, Q. (2016). Fuzzy-clustering embedded regression for predicting student academic performance. In *En 2016 IEEE International Conference on Fuzzy Systems* (p. 344-351). FUZZ-IEEE.
- Lockwood, C., Munn, Z., y Porritt, K. (2015). Qualitative research synthesis: Methodological guidance for systematic reviewers utilizing meta-aggregation. *International Journal of Evidence-Based Healthcare*, 13(3), 179-187. <https://doi.org/10.1097/XEB.0000000000000062>
- Ma, C., Yao, B., Ge, F., Pan, Y., y Guo, Y. (2017). Improving Prediction of Student Performance based on

- Multiple Feature Selection Approaches. In *En 2017 International Conference on E-Education, E-Business and E-Technology ICEBT 2017* (p. 38-43).
- Maitra, S., Eshrak, S., Bari, A., Al-Sakin, A., Hossain, R., Akter, N., y Haque, Z. (2019). Prediction of Academic Performance Applying NNs: A Focus on Statistical Feature-Shedding and Lifestyle. *International Journal of Advanced Computer Science and Applications(IJACSA)*, 10(9), 561-70. <http://dx.doi.org/10.14569/IJACSA.2019.0100974>
- Maitra, S., Madan, S., y Mahajan, P. (2018). An Adaptive Neural Fuzzy Inference System for prediction of student performance in Higher Education. In *International Conference on Advances in Computing, Communication Control and Networking (ICACCCN). Greater Noida (UP)* (p. 1158-1163).
- Martinez-Rodriguez, R. A., Alvarez-Xochihua, O., Victoria, O. D. M., Aramburo, A. J., y Fraga, J. A. G. (2019). Use of Machine Learning to Measure the Influence of Behavioral and Personality Factors on Academic Performance of Higher Education Students. *IEEE Latin America Transactions*, 17(04), 633-641. <https://doi.org/10.1109/TLA.2019.8891928>
- Matcha, W., Gašević, D., Uzir, N. A., Jovanović, J., y Pardo, A. (2019). Analytics of Learning Strategies. In *En 9th International Conference on Learning Analytics y Knowledge - LAK19* (p. 461-470).
- Meca, I., Mollá-Campello, N., y Rabasa, A. (2019). A new methodology for early warning of critical academic performance, based on discrete predictive models. In *En Seventh International Conference on Technological Ecosystems for Enhancing Multiculturality (TEEM'19)* (p. 680-685). Association for Computing Machinery.
- Mendoza-Macías, M., y Barcia-Briones, M. (2020). Las relaciones familiares y rendimiento académico en estudiantes de educación básica. *Dominio de las Ciencias*, 6, 378-394. <http://dx.doi.org/10.23857/dc.v6i3.1223>
- Mishra, T., Kumar, D., y Gupta, S. (2014). Mining Students' Data for Prediction Performance. *Fourth International Conference on Advanced Computing y Communication Technologies*, 255-263.
- Moreno-Marcos, P. M., Pong, T. C., Munoz-Merino, P. J., y Kloos, C. D. (2020). Analysis of the Factors Influencing Learners' Performance Prediction With Learning Analytics. *IEEE Access*, 8, 5264-5282. <https://doi.org/10.1109/ACCESS.2019.2963503>
- Musso, M., Kyndt, E., Cascallar, E., y Dochy, F. (2013). Predicting general academic performance and identifying the differential contribution of participating variables using artificial neural networks. *Frontline Learn. Res*, 1, 42-71. <https://doi.org/10.14786/flr.v1i1.13>
- Na, K. S., y Tasir, Z. (2017). Identifying at-risk students in online learning by analysing learning behaviour: A systematic review. *En 2017 IEEE Conference on Big Data and Analytics (ICBDA)*, 118-123.
- Palominos, F., Díaz, H., Palominos, S., y Cañete, L. (2018). Relación entre los Procedimientos de Selección a la Educación Superior y el Desempeño Académico de los Estudiantes con base en una Clasificación mediante Conjuntos Difusos. *Formación universitaria*, 11(1), 45-52. <https://doi.org/10.4067/S0718-50062018000100045>
- Pandey, M., y Taruna, S. (2016). Towards the integration of multiple classifier pertaining to the Student's performance prediction. *Perspectives in Science*, 8, 364-366. <https://doi.org/10.1016/j.pisc.2016.04.076>
- Pardo, A., Mirriahi, N., Martínez-Maldonado, R., Jovanovic, J., Dawson, S., y Gašević, D. (2016). Generating actionable predictive models of academic performance. In *En Sixth International Conference on Learning Analytics y Knowledge - LAK '16* (p. 474-478).
- Petersen, K., Feldt, R., Mujtaba, S., y Mattsson, M. (2008). Systematic mapping studies in software engineering. *12th International Conference on Evaluation and Assessment in Software Engineering*, 68-77.
- Petrucci, J., Pirouz, S. H., Pirouz, M., y B. (2013). Application of fuzzy logic for performance evaluation of academic students. *En 2013 13th Iranian Conference on Fuzzy Systems (IFSC)*.
- Popescu, E., y Leon, F. (2018). Predicting Academic Performance Based on Learner Traces in a Social Learning Environment. *IEEE Access*, 6, 72774-72785. <https://doi.org/10.1109/ACCESS.2018.2882297>
- Quinn, R., y Gray, G. (2020). Prediction of student academic performance using Moodle data from a Further Education setting. *Irish Journal of Technology Enhanced Learning*, 5(1). <https://doi.org/10.22554/ijtel.v5i1.57>
- Rahul, R., y Katarya, R. (2019). A Review: Predicting the Performance of Students Using Machine learning Classification Techniques. In *Third International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)* (p. 36-41).
- Ranjeeth, S., Latchoumi, T. P., y Paul, P. V. (2020). A Survey on Predictive Models of Learning Analytics. *Procedia Computer Science*, 167, 37-46. <https://doi.org/10.1016/j.procs.2020.03.180>
- Rastrollo-Guerrero, J. L., Gómez-Pulido, J. A., y Durán-Domínguez, A. (2020). Analyzing and Predicting Students' Performance by Means of Machine Learning: A Review. *Applied Sciences*, 10(3). <https://doi.org/10.3390/app10031042>
- Red, L., Karanik, D. L., Giovannini, M., Pinto, M., y N. (2015). Perfiles de Rendimiento Académico: Un Modelo basado en Minería de datos. *Campus Virtuales*(1), 12-30.
- Rienties, B., Herodotou, C., Olney, T., Schencks, M., y Boroowa, A. (2018). Making sense of learning analytics dashboards: A technology acceptance perspective of 95 teachers. *The International Review of Research in Open and Distributed Learning*, 19(5). <https://doi.org/10.19173/irrodl.v19i5.3493>
- Rio, C. D., y Pineda, J. (2016). Predicting academic performance in traditional environments at higher-education

- institutions using data mining: A review. *ECOS DE LA ACADEMIA*, 2(4), 185-201.
- Romero, C., Márquez, V., y Ventura, S. (2012). Predicción del Fracaso Escolar Mediante Técnicas de Minería de Datos. *lee-Rita*, 7(3), 109-117.
- Rubiano, S. M. M., y Garcia, J. A. (2016). Analysis of Data Mining Techniques for Constructing a Predictive Model for Academic Performance. *IEEE Latin America Transactions*, 14(6), 2783-2788. <https://doi.org/10.1109/TLA.2016.7555255>
- Salam, S. D., Paul, P., Tabassum, R., Mahmud, I., Ullah, M. A., Rahman, A., y Rahman, R. M. (2018). Determination of Academic Performance and Academic Consistency by Fuzzy Logic. In *International Conference on Intelligent Systems (IS)*.
- Shahiri, A. M., Husain, W., y Rashid, N. A. (2015). A Review on Predicting Student's Performance Using Data Mining Techniques. *Procedia Computer Science*, 72, 414-422. <https://doi.org/10.1016/j.procs.2015.12.157>
- Shanthini, A., Vinodhin, G., y Chandrasekaran, R. M. (2018). Predicting Students' Academic Performance in the University Using Meta Decision Tree Classifiers. *Journal of Computer Science*, 14(5), 654-662. <https://doi.org/10.3844/jcssp.2018.654.662>
- Shingari, I., Kumar, D., y Khetan, M. (2017). A review of applications of data mining techniques for prediction of students' performance in higher education. *Journal of Statistics and Management Systems*, 20(4), 713-722. <https://doi.org/10.1080/09720510.2017.1395191>
- Son, L. H., y Fujita, H. (2018). Neural-fuzzy with representative sets for prediction of student performance. *Applied Intelligence*, 49, 172-187. <https://doi.org/10.1007/s10489-018-1262-7>
- Stake, R. E. (2005). *Investigación con estudio de casos*. Madrid, Morata.
- Tanabe, Y., Kagari, K., Kitanaka, Y., Takeuchi, K., y Hirokawa, S. (2017). Finding Key Integer Values in Many Features for Learners' Academic Performance Prediction. In *En 2017 9th International Conference on Education Technology and Computers-ICETC 2017* (p. 167-171).
- Taylan, O., y Karagözoğlu, B. (2009). An adaptive neuro-fuzzy model for prediction of student's academic performance. *Computers y Industrial Engineering*, 57(3), 732-741. <https://doi.org/10.1016/j.cie.2009.01.019>
- Tempelaar, D. T., Rienties, B., y Giesbers, B. (2015). In search for the most informative data for feedback generation: Learning analytics in a data-rich context. *Computers in Human Behavior*, 47, 157-167. <https://doi.org/10.1016/j.chb.2014.05.038>
- Torres, P. V., González, C. S., Aciar, S. V., y Morales, G. R. (2018). Methodology for systematic literature review applied to engineering and education. *IEEE Global Engineering Education Conference (EDUCON)*, 1364-1373.
- Urrutia, G., y Bonfill, X. (2010). PRISMA declaration: A proposal to improve the publication of systematic reviews and meta-analyses. *Med. Clínica*, 135(11), 507-511. Retrieved from <https://bit.ly/3bZ3X0R>
- Urteaga, I., Siri, L., y Garófalo, G. (2020). Predicción temprana de deserción mediante aprendizaje automático en cursos profesionales en línea. *RIED. Revista Iberoamericana de Educación a Distancia*, 23(2), 147-167. <https://doi.org/10.5944/ried.23.2.26356>
- Viberg, O., Hatakka, M., Bälter, O., y Mavroudi, A. (2018). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 89, 98-110. <https://doi.org/10.1016/j.chb.2018.07.027>
- Waheed, H., Hassan, S. U., Aljohani, N. R., Hardman, J., y Nawaz, R. (2020). Predicting Academic Performance of Students from VLE Big Data using Deep Learning Models. *Computers in Human Behavior*. <https://doi.org/10.1016/j.chb.2019.106189>
- Yadav, R. S., Soni, A. K., y Pal, S. (2014). A study of academic performance evaluation using Fuzzy Logic techniques. *En 2014 International Conference on Computing for Sustainable Global Development (INDIACom)*, 48-53.
- Yao, H., Lian, D., Cao, Y., Wu, y Zhou, T. (2019). Predicting Academic Performance for College Students: A Campus Behavior Perspective. *ACM Trans. Intell. Syst. Technol*, 10(3), 1-21. <https://doi.org/10.1145/3299087>
- Yildiz, O., Bal, A., y Gulsecen, S. (2013). Improved fuzzy modelling to predict the academic performance of distance education students. *The International Review of Research in Open and Distributed Learning*, 14(5), 143-165. <https://doi.org/10.19173/irrodl.v14i5.1595>
- Zaldumbide, J. P., y Párraga, V. (2018). Systematic Mapping Study of Literature on Educational Data Mining to determine factors that affect school performance. In *En 2018 International Conference on Information Systems and Computer Science (INCISCOS)* (p. 239-245).
- Zambrano, C., Urrutia, A., y Varas, M. (2017). Análisis de rendimiento académico estudiantil usando Data Warehouse Difuso. *Ingeniare. Revista chilena de ingeniería*, 25, 242-254. <https://dx.doi.org/10.4067/S0718-330520170002002422>
- Zuviria, N. M., Mary, S. L., y Kuppammal, V. (2012). SAPM: ANFIS based prediction of student academic performance metric. In *En 2012 Third International Conference on Computing, Communication and Networking Technologies (ICCCNT'12)*.