

---

## **Diagnóstico académico de los estudiantes de ingenierías con el uso de inteligencia artificial**

Academic diagnosis of engineering students with the use of artificial intelligence

Yumilka Bárbara Fernández Hernández<sup>1</sup>, <https://0000-0002-9569-5348>

Hilda López León<sup>1</sup>, <https://0000-0003-2174-5266>

Olga Lidia Pérez González<sup>1</sup>, <https://0000-0003-4475-814X>

Julio Cesar Madera Quintana<sup>1</sup>, <https://0000-0001-5551-690X>

<sup>1</sup> Universidad de Camagüey, Camagüey, Cuba

[yumilka.fernandez@reduc.edu.cu](mailto:yumilka.fernandez@reduc.edu.cu)

[hilda.lopez@reduc.edu.cu](mailto:hilda.lopez@reduc.edu.cu)

[olga.perez@reduc.edu.cu](mailto:olga.perez@reduc.edu.cu)

[julio.madera@reduc.edu.cu](mailto:julio.madera@reduc.edu.cu)

### **Resumen**


**Objetivo:** Exponer los resultados de un diagnóstico académico aplicado a estudiantes del primer año de las carreras de ingeniería, utilizando métodos y técnicas de inteligencia artificial.

**Métodos:** Se empleó la entrevista y la recopilación de datos, conformando una base de casos que toma en consideración atributos demográficos, socioeconómicos y académicos de los estudiantes. Se utilizan métodos teóricos, estadísticos y de minería de datos con el uso de técnicas de selección de atributos, algoritmos de clasificación y predicción para realizar dicho diagnóstico en un grupo de estudiantes.

**Resultados:** Se aportó el diseño para la realización del diagnóstico académico. Además, en la aplicación del diagnóstico se identificaron que los atributos índices académico, centro de procedencia, escalafón y resultados de los exámenes de ingreso de matemática y español, son los que tienen mayor peso al momento de diagnosticar a los estudiantes del primer año de las ingenierías.

**Conclusiones:** En esta investigación se aplicaron técnicas de inteligencia artificial para lograr predecir y diagnosticar a los estudiantes que cursan primer año en las especialidades de Eléctrica, Mecánica, Informática, Civil, Industrial, Química y Agronomía. Se demuestra la utilidad de aplicar diferentes modelos de inteligencia artificial al proceso de diagnóstico académico.

**Palabras clave:** Educación Superior, diagnóstico académico, inteligencia artificial, acceso a la educación.



## Abstract

**Objective:** To describe the results of an academic diagnostic test given to first year engineer students, using artificial intelligence methods and techniques.

**Methods:** Interview and data collection were used, configuring a case base that takes into consideration demographic, socioeconomic and academic attributes of the students. Theoretical, statistical and data mining methods are used with the use of attribute selection techniques, classification and prediction algorithms to perform such diagnosis in a group of students.

**Result:** The authors devise a tool for academic diagnosis based artificial intelligence. It identifies the among the most relevant attributes, the academic indexes, the center of origin, the rank and results of the admittance exams in mathematics and Spanish.

**Conclusion:** In this research, artificial intelligence techniques were applied to achieve prediction and diagnosis of first year students in the specialties of Electrical, Mechanical, Computer Science, Civil, Industrial, Chemistry and Agronomy. The usefulness of applying different artificial intelligence models to the academic diagnosis process is demonstrated.

**Keywords:** Higher education, educational diagnosis, access to education


**Recibido:** 10 de julio de 2023

**Aprobado:** 30 de septiembre de 2023

## Introducción

La deserción o el abandono escolar constituye un tema de especial relevancia en los sistemas educativos, el tema de (Bernárdez-Gómez et al., 2021), y la academia no se encuentra exenta de esta preocupación, por lo que resulta de vital importancia conocer las causas que lo provocan, para tomar las medidas de prevención necesarias, puesto que tiene consecuencias sociales y emocionales de acuerdo a las expectativas de los estudiantes y sus familias, por la disonancia entre las aspiraciones de los jóvenes y sus logros. Adicionalmente, este hecho tiene importantes consecuencias económicas, tanto para las personas como para la institución al asignarse numerosos recursos que no son aprovechados de manera óptima y eficiente (Allpas, 2018, Martí et al., 2023).

El diagnóstico en las ciencias pedagógicas ha sido definido por diferentes investigadores. En la actualidad los más representativos, a criterio de los autores, son: Prieto-López & Ayala-Pazmiño (2020) y Tenesaca et al. (2021). Partir del diagnóstico y mantenerlo durante todo el proceso es fundamental para conocer los fenómenos educativos con rigor, constituyendo un paso previo necesario para intervenir adecuadamente sobre ellos. Los contextos educativos se han transformado como consecuencia de cambios sociales, económicos y tecnológicos y en este



escenario resulta cada vez más necesario su presencia activa y colaborativa en los contextos escolares y extraescolares.

Una de las posibles soluciones al problema del abandono escolar puede ser la realización de un adecuado diagnóstico de los estudiantes, desde que estos comienzan su vida universitaria (Ramentol et al., 2019). En las universidades como parte de la gestión académica debe considerarse la dimensión diagnóstica, pues esta adquiere carácter de sistema en la representación del conocimiento sobre la actividad académica del estudiante, así como en la valoración para la posible intervención de identificar potencialidades y necesidades de ayuda, a través del compromiso y la responsabilidad colectiva de los miembros del colectivo de profesores universitario (Fernández et al., 2023).

Un término recurrentemente en el discurso pedagógico tradicional es precisamente el de *diagnóstico educativo*, Mari (2008) lo define como:

un proceso de indagación científica, apoyado en una base epistemológica y cuyo objeto lo constituye la totalidad de los sujetos (individuos o grupos) o entidades (instituciones, organizaciones, programas, contextos familiares, socio-ambiental, etc.) considerados desde su complejidad y abarcando la globalidad de su situación, e incluye necesariamente en su proceso metodológico una intervención educativa de tipo perfectiva. (p. 2).

Mientras que Buisán & Marín (2001) lo definen como

un proceso que trata de describir, clasificar, predecir y explicar el comportamiento de un sujeto dentro del marco escolar. Incluyen un conjunto de actividades de medición y evaluación de un sujeto (o grupo de sujetos) o de una institución con el fin de dar una orientación. (p.13)

El fin del diagnóstico educativo no es atender las deficiencias de los sujetos y su recuperación, sino una consideración nueva que podemos llamar pedagógica: proponer sugerencias e intervenciones perfectivas, bien sobre situaciones deficitarias para su corrección o recuperación, o sobre situaciones no deficitarias para su potenciación, desarrollo o prevención (Arriaga, 2015).

Por otra parte, el diagnóstico académico en el contexto educacional según Arias (2009), es un proceso de construcción del conocimiento acerca de algo sobre lo que se va a intervenir y actuar, mientras que López & Borgato (2002) plantean que es un principio pedagógico, premisa imprescindible, procedimiento científico en función de la labor educativa y del desarrollo de todos los estudiantes. Es un factor indispensable para explicar, guiar el aprendizaje y el desarrollo de los estudiantes, basado esencialmente en la búsqueda constante de los antecedentes del desarrollo, de lo alcanzado por el individuo y de las potencialidades que el sujeto tiene para alcanzar nuevos desarrollos a partir de los resultados arrojados por las diferentes fuentes de obtención de información. Nótese como estos autores destacan el valor de las potencialidades desde una posición cónsona con el enfoque histórico cultural.

Otros destacados investigadores han tomado al diagnóstico académico como objeto de estudios, entre ellos se encuentran García (2007), Marí (2008), Cantabella et al. (2019), Luzardo et al.

(2022) y Espinoza et al. (2022). Un estudio realizado por Luzardo et al. (2022), deja ver como en diversas regiones del mundo ese proceso se ha estado identificando con diferentes denominaciones, como son: diagnóstico educativo, diagnóstico en educación, diagnóstico académico y evaluación diagnóstica. Las cuales se orientan al análisis de la realidad académica para describir, clasificar, predecir y explicar el comportamiento del estudiante dentro del marco escolar, atendiendo a variables demográficas, socioeconómicas y académicas.

A partir de la sistematización realizada los autores conciben al diagnóstico académico como herramienta de gestión en función de la atención personalizada al estudiante desde el colectivo de profesores, para identificar las necesidades educativas del mismo respecto a su actividad académica.

De ese modo, el diagnóstico académico se considera como componente de la gestión académica que favorece la consistencia, organización y cohesión al trabajo del colectivo de profesores universitario y al decir de Yurell et al. (2018) debe desarrollarse a través de tres fases:

1. La caracterización del fenómeno objeto de investigación.
2. El pronóstico de sus tendencias de cambio.
3. La proyección de las acciones que conduzcan a su transformación.

Las investigaciones sobre el diagnóstico académico han enfatizado en la tercera fase y poco se ha trabajado en la primera y segunda incluyendo el uso de técnicas inteligentes para la representación del conocimiento del estudiante y la correspondiente predicción de sus posibles necesidades de ayuda.

Autores como Díaz-Landa et al. (2021) y Castrillón et al. (2020) muestran diversas investigaciones donde se aplica la inteligencia artificial para resolver problemas del año educativo universitario desde la perspectiva de la predicción de la lealtad a la universidad, el rendimiento académico, el comportamiento sobre aula invertida y aprendizaje colaborativo, las analíticas de aprendizaje, resolución de dudas sobre procesos académicos, las causas de reprobación y el análisis de la deserción de estudiantes universitarios mediante minería de datos.

Como herramientas que nos brinda la ciencia y que puede ser de gran utilidad en este proceso está el aprendizaje automático o *machine learning*, como área de la inteligencia artificial que se ocupa de desarrollar técnicas capaces de aprender, es decir, extraer de forma automática conocimiento subyacente en la información que puede contribuir a la solución del problema que se aborda. Esta es una alternativa viable, que puede utilizar un centro de educación superior (CES) con un cúmulo de información útil, para el estudio de la deserción mediante el uso de técnicas de minería de datos con el objetivo de predecir, de forma automatizada tendencias o comportamientos y descubrir modelos previamente desconocidos (Frawley & Piatetsky-Shapiro, 1992; Díaz-Landa et al., 2021).

De ahí que el objetivo del artículo es dar a conocer los resultados de un diagnóstico académico aplicado a estudiantes del primer año de las carreras de ingeniería utilizando métodos y técnicas

de inteligencia artificial, las que permitirán predecir sus resultados académicos y los atributos que tienen mayor influencia en estos resultados.

### **Métodos**

Se aplicaron los métodos análisis y síntesis, inducción-deducción, así como el análisis documental y la entrevista. De la inteligencia artificial se utilizaron la selección de atributos, la clasificación y algoritmo de predicción. La sustentación, diseño y aplicación del diagnóstico se desarrolló en dos momentos, en el primero se utilizaron métodos teóricos que permitieron la sistematización teórica en relación al tema, así como la definición de diagnóstico académico inteligente. En un segundo momento los métodos y técnicas de inteligencia artificial posibilitaron la predicción de los resultados académicos y los atributos de los estudiantes que tienen mayor importancia en los mismos.

Para el desarrollo del segundo momento se trabajó el diagnóstico académico utilizando técnicas de inteligencia artificial en cuatro etapas. La primera etapa consistió en la elección de los atributos que se tienen en cuenta para este diagnóstico, a través de entrevistas realizadas a expertos y el análisis de bibliografía sobre este tema. En la segunda etapa se asimiló la información relacionada con las variables del proceso educativo en soporte digital creando la base de conocimiento con esos datos.

Como tercera etapa del proceso de diagnóstico académico, se utilizan métodos y técnicas de inteligencia artificial para analizar los datos de los atributos obtenidos de la etapa anterior y definir cuáles de estos tienen mayor importancia para el diagnóstico. En una cuarta etapa se predicen los resultados académicos de los estudiantes en primer año de las carreras de ingeniería, por lo que para el estudio presentado en esta investigación se utilizan dos modelos: RFE.DOWN.RF (Ali et al., 2012; Espinar, 2018; Guyon et al., 2002) y RFE.DOWN.TREEBAG (Aguirre et al., 2007; Espinar, 2018; Guyon et al., 2002).

El modelo RFE.DOWN.RF se compone del algoritmo de selección de atributos RFE, por sus siglas en inglés de Recursive Feature Elimination; el algoritmo de balanceo de datos, DOWN y el de clasificación-predicción RF (Random Forest); mientras que el modelo RFE.DOWN.TREEBAG se compone del algoritmo de selección de atributos RFE; el algoritmo de balanceo de datos, DOWN y el de clasificación-predicción, TREEBAG. El uso de estos modelos hizo posible la predicción de los resultados académicos de los alumnos que se tuvieron en cuenta para este estudio.

Estos modelos se corrieron en la herramienta informática R (Valentín-Bravo et al., 2023), que utiliza un lenguaje computacional muy potente para la realización de cálculos científicos, estadísticos y la aplicación de algoritmos y métodos de inteligencia artificial, favoreciendo la creación de gráficas de gran calidad.

### **Resultados**

Como resultado de la primera etapa se muestran en la tabla 1 el número total de estudiantes que se tuvieron en cuenta para la obtención de los datos: de ellos fueron 477 clasificados como sin dificultades en el aprendizaje (SDA), siendo aquellos que logran promover al segundo año de



la carrera sin arrastres de asignaturas y que representa el 61.53% del total de los analizados, los 310 restantes se clasifican como estudiantes con dificultades en el aprendizaje (CDA), que son los que no logran promover al segundo año de la carrera y representan el 39.47%.

**Tabla 1.** Número de estudiantes que presentan dificultades en el aprendizaje y los que no presentan dificultades

	Número de estudiantes	Porcentaje (%)
Estudiantes sin dificultades en el aprendizaje	477	60.61
Estudiantes con dificultades en el aprendizaje	310	39.39
<b>Total</b>	<b>787</b>	<b>100.00</b>

Fuente: Elaboración propia

Por su parte, en la Tabla 2 se muestra el número de estudiantes por carreras de ingenierías.

**Tabla 2.** Número de estudiantes por carreras de ingeniería

Ingenierías	Número de estudiantes
Eléctrica	107
Mecánica	111
Informática	117
Civil	144
Industrial	154
Química	78
Agronomía	76

Nota. Fuente: Elaboración propia

Según el criterio de los expertos, el estudio de la bibliografía sobre el tema y los datos almacenados con que cuenta el centro universitario que se estudia, los atributos de los estudiantes que se tuvieron presente se muestran en la tabla 3, para un total de 21 atributos que tienen en cuenta los datos demográficos, socioeconómicos y académicos.

**Tabla 3.** Atributos analizados en cada estudiante

DATOS	ATRIBUTOS
DEMOGRÁFICOS	Municipio
	Sexo
	Edad
	Color de la piel
	Tipo de servicio militar
	Natural de
SOCIOECONÓMICOS	Organización política
	Estudios realizados por el padre
	Estudios realizados por la madre
	Teléfono

ACADÉMICOS


Centro de procedencia
Carrera
Situación académica
Tipo de estudiante
Índice académico
Escalafón
Español
Matemática
Historia
Convocatoria
Opción

Fuente: Elaboración propia

Como resultado de la segunda etapa se asimilaron los datos y se creó la base de conocimiento, utilizando el formato de los datos en inteligencia artificial.

En la tercera etapa se aplicó el modelo RFE.DOWN.RF, que se muestra en la figura 1 la importancia de los atributos utilizados. Donde se observa que quedan en orden de relevancia: Índice Académico (IA), Centro de procedencia (Centro Procedencia), Escalafón (Esc), resultados obtenidos en las pruebas de ingreso de matemática (Mat) y de español (Esp).

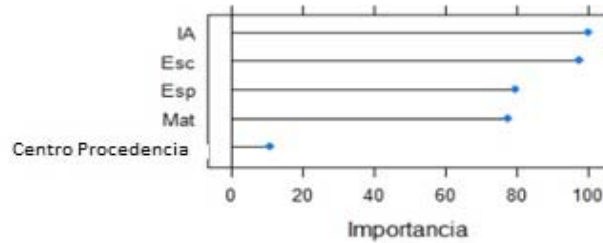
Figura 1. Importancia de los atributos en el modelo predictivo



Fuente: Elaboración propia

Además como parte de la tercera etapa se utilizó el segundo modelo RFE.DOWN.TREEBAG que también determinó la importancia de los atributos, donde el Índice Académico (IA) alcanza el primer lugar en el orden de relevancia, como se muestra en la figura 2.

Figura 2. Importancia de los atributos en el modelo predictivo



Fuente: Elaboración propia

En la cuarta y última etapa se logra predecir los resultados académicos de los estudiantes, como se muestra en la Figura 3. Donde se observa en la primera columna los datos del centro de procedencia, en la segunda columna el índice académico, a continuación, el escalafón, luego las notas obtenidas en las pruebas de ingreso de Matemática, le siguen las de Español y por último se obtiene el resultado de la predicción: si el estudiante resulta Con dificultades en el aprendizaje (CP) o Sin dificultades en el aprendizaje (SP).

Figura 3. Predicción realizada utilizando el modelo RFE+DOWN+ TREEBAG.

```
#Probar nuevos Estudiantes
#rfe solo necesita CentroProcedencia,IA,Esc,Mat,Esp

# CentroProcedencia IA Esc Mat Esp Resultado
#1 IPUMAXIMOGOMEZ 94.65 86.99 70 79 CP
#2 IPUBERNABEBOZA 98.55 96.94 94 93 SP
#3 CMRAULHERNANDEZ 85.80 72.90 60.0 60.0 CP
#4 ROBERTOESPINO 81.13 75.56 60.0 72.0 CP
#5 IPVCEMAXIMOGOMEZ 70.50 87.29 70.5 93.0 CP
#6 IPVCEMAXIMOGOMEZ 99.2 98.26 100 96 SP

#Leyendo el modelo obtenido para aplicarlo a nuevas instancias y pronosticar
treebagFit_OK_rfe.down.Model <- readRDS("F:/hilda/entrenamiento/rfe/RFE+DOWN+TREEBAG.rds")
```

Fuente: Elaboración propia

## Discusión

A la combinación de los algoritmos utilizados para realizar la selección de atributos, la clasificación y la predicción de los datos se les denomina modelo. En el apartado anterior como se puede observar se utilizan dos modelos. Uno de ellos el RFE.DOWN.RF y el otro RFE.DOWN.TREEBAG. En el proceso de selección de atributos el algoritmo elige aquellos atributos que mayor relevancia tienen en una base de casos determinada, por otro lado la clasificación y la predicción de datos permite obtener un resultado predictivo del atributo final que se desea conocer, en este caso, es la necesidad de ayuda del estudiante.

Yang et al. (2021) y YiLin et al. (2021), plantean la importancia de utilizar modelos de inteligencia artificial en diferentes áreas de la educación con el fin de lograr una predicción eficaz.

En el primer modelo tiene mayor importancia el atributo índice académico (IA). En el orden obtenido le siguen el centro de procedencia, el escalafón y los resultados obtenidos en las pruebas de ingreso de Matemática y de Español. Se observa que los factores académicos son los



más influyentes para lograr un adecuado diagnóstico estudiantil en primer año de las carreras de ingenierías en la universidad.

En el segundo modelo los resultados obtenidos son similares, solamente difieren en el orden de las variables, donde se ordenan por: índice académico, escalafón, Español, Matemática y centro de procedencia, quedando como las primeras cinco variables que influyen en la obtención de resultados satisfactorios por parte de los estudiantes en ambos modelos.

Es concluyente que los factores académicos son los de mayor peso a tener en cuenta para valorar el abandono universitario, así como para realizar un adecuado diagnóstico académico en los estudiantes, coincidiendo con el estudio realizado por Constante et al. (2021).

Otros estudios que utilizan técnicas de inteligencia artificial para la predicción de resultados académicos (Cachón et al., 2019) coinciden que los factores docentes son los de mayor influencia en esta rama educativa, aunque otras investigaciones como la de Contini et al. (2018) señalan la importancia que juega el nivel educativo de los padres y en Fernández et al. (2019) se declara el valor que ocupa la naturaleza socioeconómica de los estudiantes, teniendo en cuenta el acceso a las becas y el trabajo laboral realizado por el mismo.

De esta manera la aplicación del diagnóstico académico utilizando inteligencia artificial apoya y contribuye a la toma de decisiones de los docentes. En el caso de los estudiantes que resultaron con dificultades en el aprendizaje: determinar un grupo de acciones para elevar su preparación y aquellos que fueron diagnosticados sin dificultades en el aprendizaje: planificar acciones que contribuyan a lograr un mayor aprovechamiento de sus conocimientos.

## Conclusiones

La realización del diagnóstico académico en estudiantes de primer año de las carreras de ingeniería, en la Universidad de Camagüey partió del diseño del mismo, utilizando métodos y técnicas de inteligencia artificial. Esto permitió predecir los resultados académicos de los estudiantes que cursan primer año en las especialidades de: Eléctrica, Mecánica, Informática, Civil, Industrial, Química y Agronomía.


Se demostró la utilidad de aplicar diferentes modelos de inteligencia artificial al proceso de diagnóstico académico, concluyendo que los factores precedentes como: índice académico, centro de procedencia, escalafón, y los resultados de los exámenes de ingreso de Matemática y Español, tienen mayor peso en el momento de diagnosticar a los estudiantes del primer año de las ingenierías.

## Referencias

- Aguirre, M., Jeltsch, E. & Rosales, G. (2007). Una visualización de un sistema de inferencia a través de trebag. *Revista Chilena de Ingeniería*, 15(1), 92-100.  
<https://www.scielo.cl/pdf/ingeniare/v15n1/Art12.pdf>



- Ali, J., Khan, R., Ahmad, N. & Maqsood, I. (2012). Random forests and decision trees. *IJCSI International Journal of Computer Science Issues*, 9(5), 272-278. <http://ijcsi.org/papers/IJCSI-9-5-3-272-278.pdf>
- Allpas, N. (2018). *Factores que influyen en el nivel de deserción de los estudiantes del programa de actualización y perfeccionamiento de la academia de la magistratura*. Tesis de grado inédita. Universidad San Ignacio de Loyola. Lima, Perú.  
<https://repositorio.usil.edu.pe/entities/publication/23a453e5-e31f-46f7-ad9f-640a6f1113ba>
- Arias, G. (2009). La psicología educacional y el sistema de educación en Cuba. *Revista Semestral da Associação Brasileira de Psicologia Escolar e Educacional (ABRAPPEE)*, 13(1), 155-164.  
<http://pepsic.bvsalud.org/pdf/pee/v13n1/v13n1a17.pdf>
- Arriaga, M. (2015). El diagnóstico educativo, una importante herramienta para elevar la calidad de la educación en manos de los docentes. *Atenas*, 31(3), 63-74.  
<https://www.redalyc.org/pdf/4780/478047207007.pdf>
- Bernárdez-Gómez, A., Álvarez, J. S. & Belmonte, M. L. (2021). Review of educational research on drop-out. *Bibliometric trends. Research, Society and Development*, 10(1), p.[1-12].  
<http://dx.doi.org/10.33448/rsd-v10i1.12193>
- Buisán, C. & Marín, M. A. (2001). *Cómo realizar un diagnóstico pedagógico*. **Riobamba**: Alfaomega Grupo Editor. <https://dialnet.unirioja.es/servlet/libro?codigo=158966>
- Cachón, G. C., Martínez, R. G., Navalón, J. G. & Roman, C. P. (2019). Inteligencia artificial para predecir la lealtad a la universidad. *Journal of Management and Business Education*, (2), 17- 27.  
<https://doi.org/10.35564/jmbe.2019.0003>
- Cantabella, M., Martínez, R., Ayuso, B., Yañez, J. A. & Muñoz, A. (2019). Analysis of student behavior in learning management systems through a Big Data framework. *Future Generation Computer Systems*, (90), 262-272. <https://doi.org/10.1016/j.future.2018.08.003>
- Castrillón, O. D., Sarache, W. & 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>
- Constante, A., Florenciano, E., Navarro, E. & Fernández, M. (2021). Factores asociados al abandono universitario. *Educación XXI*, 24(1), 17-44.  
<https://revistas.uned.es/index.php/educacionXX1/article/view/26889/24836>
- Contini, D., Cugnata, F. & Scagni, A. (2018). Social selection in higher education. Enrolment, dropout and timely degree attainment in Italy. *Higher Education*, 75(5), 785-808.  
<https://doi.org/10.1007/s10734-017-0170-9>
- Díaz-Landa, B., Meleán-Romero, R. & Marín-Rodríguez, W. (2021)). Rendimiento académico de estudiantes en Educación Superior: predicciones de factores influyentes a partir de árboles de decisión. *Telos: Revista de Estudios Interdisciplinarios en Ciencias Sociales*, 23(3), 616-639.  
<https://doi.org/10.36390/telos233.08>
- Espinar, R. (2018). *Modelos de Clasificación con datos no balanceados*. Tesis de grado inédita.



Universidad de Sevilla, España.

<https://idus.us.es/bitstream/handle/11441/77518/Espinar%20Lara%20Roc%C3%ADo%20TFG.pdf?sequence=1>

Espinoza, V. M., Santana, A. L. & Rubiales, F. S. (2022). Diagnóstico sobre rezago escolar en el Colegio de Ciencias y Humanidades. *Revista RedCA*, 12(4), 176-191.

<https://doi.org/10.36677/redca.v4i12.16619>

Fernández, T., Solís, M., Hernández, M. & Moreira-Mora, T. E. (2019). Un análisis multinomial y predictivo de los factores asociados a la deserción universitaria. *Revista Electrónica Educare*, (23), 73-97. <http://dx.doi.org/10.15359/ree.23-1.5>

Fernández, Y., Pérez, O. & Caballero, Y. (2023). Diagnóstico académico en el colectivo de profesores universitario con Inteligencia Artificial. *Revista Paradigma*, 44(2), 47-60.

<http://dx.doi.org/10.37618/PARADIGMA.1011-2251.2023.pxy-wz.id0000>

Frawley, W. J., Piatetsky-Shapiro, G. & Matheus, C. J. (1992). Knowledge Discovery in Databases: An Overview. *AI Magazine*, 13(3), 57-70.

<https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/1011>

García, N. (2007). Marco de referencia actual para el diagnóstico pedagógico. *Tendencias pedagógicas*, (12), 83-110. <http://hdl.handle.net/11162/122002>.

Guyon, I., Weston, J., Barnhill, S. & V., V. (2002). Gene selection for cancer classification using support vector machines. *Machine learning*, 46(1), 389-422.

<http://www.thespermwhale.com/jaseweston/GENESEL.PDF>

López, J. H. & Borgato, A. (2002). Formación de la habilidad de análisis sonoro de la palabra en niños del sexto año de vida (cinco años de edad). En S. L. Lorenzo, L. A. Cao & A. M. S. Gómez, *Estudio sobre las particularidades del desarrollo del niño preescolar cubano*. (pp. 216-226). Pueblo y Educación.

Luzardo, H., Molina, T. J. & Godoy, T. C. (2022). Diagnóstico académico de la educación superior, analizando el aprendizaje mediante modalidad virtual. *Revista Conrado*, 18(53), 84-93.

<https://conrado.ucf.edu.cu/index.php/conrado/article/view/2640/2566>

Mari, R. (2008). *Propuesta de un modelo de diagnóstico en educación*.

<http://biblioteca.udgvirtual.udg.mx/jspui/handle/123456789/2710>

Martí, Y., Montero, B., M. & Contreras, M. (2023). Estudio diagnóstico en la función social del psicopedagogo como contenido de la formación inicial y permanente. *Transformación*, 19 (1), 215-230. <http://scielo.sld.cu/pdf/trf/v19n1/2077-2955-trf-19-01-215.pdf>

Prieto-López, Y. & Ayala-Pazmiño, M. (2020). Modelo pedagógico de supervisión, evaluación y acompañamiento a los docentes de la Unidad Educativa Bilingüe Torremar (UEBT). *Digital Publisher CEIT* (4), 69-77.

[https://www.593dp.com/index.php/593\\_Digital\\_Publisher/article/view/218](https://www.593dp.com/index.php/593_Digital_Publisher/article/view/218).


Ramentol, E., Madera, J. & Rodríguez, A. (2019). Early detection of possible undergraduate drop out



- using a new method based on probabilistic rough set theory. In R. Bello, R. Falcon & J. Verdegay (eds), *Uncertainty Management with Fuzzy and Rough Sets. Studies in Fuzziness and Soft Computing, vol 377*, (pp.211 - 232). Springer, Cham  
[https://www.researchgate.net/publication/327528463\\_Early\\_Detection\\_of\\_Possible\\_Undergraduate\\_Drop\\_Out\\_Using\\_a\\_New\\_Method\\_Based\\_on\\_Probabilistic\\_Rough\\_Set\\_Theory](https://www.researchgate.net/publication/327528463_Early_Detection_of_Possible_Undergraduate_Drop_Out_Using_a_New_Method_Based_on_Probabilistic_Rough_Set_Theory)
- Tenesaca, J., Medina, I. & Álvarez, M. (2021). Pedagogical diagnosis and self-learning in the training of foreign language teachers: Diagnóstico pedagógico y autoaprendizaje en la formación de profesores de lenguas extranjeras. *South Florida Journal of Development*, 2(5), 7111-7121.  
<https://ojs.southfloridapublishing.com/ojs/index.php/jdev/article/view/880>
- Valentín-Bravo, F., Mateos, E., Usategui, R., Andrés, C., Pastor, J. & Pastor, S. (2023). Artificial Intelligence and new language models in Ophthalmology: Complications of the use of silicone oil in vitreoretinal surgery. *Archives of the Spanish Society of Ophthalmology*, 98, (5) 298-303.  
<https://www.sciencedirect.com/science/article/abs/pii/S0365669123000734>
- Yang, S. J. H., Ogata, H., Matsui, T. & Chen, N. S. (2021).. Human-centered artificial intelligence in education: Seeing the invisible through the visible. *Computers and Education: Artificial Intelligence*, 2. <https://doi.org/10.1016/j.caeai.2021.100008>
- YiLin, P., Chai, C., Siu-Yung, J., M., Dai, Y., Guo, Y. & Qin, J. (2021). *Modeling the structural relationship among primary students' motivation to learn artificial intelligence*. *Computers and Education: Artificial Intelligence*, 2. <https://www.sciencedirect.com/science/article/pii/S2666920X20300060>
- Yurell, I., Guerra, Y. & Conde, M. (2018). Diagnóstico pedagógico en el proceso docente educativo: pensamiento pedagógico de avanzada. *Revista Atlante: Cuadernos de Educación y*  
<https://www.eumed.net/rev/atlante/2018/10/diagnostico-pedagogico.html>

### Síntesis de los autores

Los autores son profesores de la Universidad de Camagüey, Cuba. Yumilka Bárbara Fernández Hernández es graduada de Ingeniería Informática (2004), M. Sc. en Telemática, y doctoranda del Centro de Estudios de Ciencias Pedagógicas de la Universidad de Camagüey. Se desempeña como Profesora Auxiliar y Jefa del Departamento de Informática de la Universidad de Camagüey, es miembro de varios proyectos nacionales e internacionales. Autora de varios artículos científicos y capítulos de libros sobre temas pedagógicos y de inteligencia artificial. Premio de la Academia de Ciencias de Cuba 2018. **Hilda López León** es Licenciada en Educación Especialidad Informática, Máster en Ciencias en Informática Aplicada. Se desempeña como Secretaria Docente de la Facultad de Informática y Ciencias Exactas. Es Profesora auxiliar y autora de diferentes artículos científicos y capítulos de libros. Investigadora sobre temas de educación universitaria e inteligencia artificial. **Olga Lidia Pérez González** Preside el Comité Latinoamericano de Matemática Educativa (CLAME) (2016-2022), coordinadora de la Red Iberoamericana de Investigadores en Matemática Educativa (desde 2020). Licenciada en Profesorado Superior, especialidad Matemática, Máster en Educación Superior, Doctora en Ciencias Pedagógicas, mención Sofía Kovalevskaja 2021. Premio Nacional "Pablo Miquel" otorgado por la SCMC (2009), Premio Nacional de la Academia de Ciencias de Cuba 2009, 2018, 2019, 2020, Orden "Carlos J. Finlay" (2015), Premio del Ministro del MES al



resultado de investigación más útil a la educación (2020), Distinción especial del Ministro (2009, 2010, 2019, 2020), Investigadora titular del MESCYT, República Dominicana (2020). Coordinadora Maestría “Enseñanza de la Matemática”, de la Universidad de Camagüey (UC), Jefa del Grupo de Investigaciones de Matemática Educativa de la UC, Profesora e Investigadora Titular del Centro de Estudios de Ciencias de la Educación de la UC. Actual coordinadora del Proyecto Nacional “Gestión didáctica innovadora de la Matemática” (código PS221LH001-043), Programa Sectorial del MINED, Investigadora del Proyecto financiado por FONDOCYT “Desarrollo Conceptual Procedimental en el Cálculo Diferencial” (2021-2024) en República Dominicana, código 2020-2021-1D3-188. **Julio Cesar Madera Quintana** es Doctor en Ciencias Matemáticas, por la Universidad de La Habana (2009); Máster en Informática Aplicada (2007), por la Universidad de Camagüey; Licenciado en Ciencias de la Computación (1997), por la Universidad Central de las Villas. Es Profesor Titular de la Universidad de Camagüey. Actualmente es el líder de varios proyectos internacionales. Profesor de varios cursos de posgrados impartidos en Cuba y en el extranjero dentro del programa de la Maestría en Informática Aplicada de la Universidad de Camagüey que incluyen: Programación Avanzada, Matemática Discreta y Computacional, Estructuras de Datos Avanzadas y Temas Selectos de Inteligencia Artificial. Premio CITMA Provincial de Camagüey en 2022. Premio Pablo Miquel de la Sociedad Cubana de Matemática y Computación en 2021 en el área de Ciencias de la Computación. Investigador Distinguido del Instituto Internacional de Investigaciones en Inteligencia Artificial de la Universidad de Estudios Internacionales de Hebei, China en 2021. Premio de la Academia de Ciencias de Cuba en 2018. Ha colaborado en la escritura de varios capítulos de libros y es autor de más de 50 artículos científicos en revistas y congresos de alto impacto.

### **Declaración de responsabilidad autoral**

**Yumilka Bárbara Fernández Hernández:** Realiza la búsqueda de información referida al tema objeto de estudio, aporta la definición de términos utilizados en esta contribución y redacta el artículo.

**Hilda López León:** Realiza la base de casos y la aplicación de los algoritmos de inteligencia artificial utilizados.

**Olga Lidia Pérez Pérez:** Facilita algunas de las referencias utilizadas y colabora en la concepción de las definiciones aportadas en el artículo.

**Julio Madera Quintana:** Orienta e indica los algoritmos a utilizar para la predicción de los estudiantes, guía el proceso de predicción.

