

Aprendizaje automático para la predicción del nivel de alfabetización en la inteligencia artificial en estudiantes universitarios

Machine learning for predicting artificial intelligence literacy levels in university students

Douglas Andrés Verduga Alcívar ^{1, *} <https://orcid.org/0000-0003-4984-0441>

Eldis Román Cao ¹ <https://orcid.org/0000-0002-8552-7906>

Neyfe Sablón Cossío ¹ <https://orcid.org/0000-0002-6691-0037>

¹Universidad Técnica de Manabí. Ecuador.

*Autor para la correspondencia: douglas.verduga@utm.edu.ec

RESUMEN

El objetivo del trabajo es aplicar técnicas de machine learning para la predicción del nivel de alfabetización en la inteligencia artificial en estudiantes que reciben estadística en la Universidad Técnica de Manabí. La metodología de investigación incluye el entrenamiento de una red neuronal y de máquinas de soporte vectorial (SVM) para predecir el nivel de alfabetización en la inteligencia artificial en estudiantes universitarios. La novedad de este trabajo reside en la posibilidad de definir con antelación las necesidades de los estudiantes en cuanto a la alfabetización de las AI, lo que permitirá las intervenciones tempranas y personalizadas en el proceso de aprendizaje.

Palabras clave: inteligencia artificial; machine learning; redes neuronales; máquina de soporte vectorial.

ABSTRACT

The objective of this study is to apply machine learning techniques to predict the level of artificial intelligence (AI) literacy among students enrolled in statistics courses at the Technical University of Manabí. The research methodology includes the training of a neural network and support vector machines (SVM) to forecast AI literacy levels in university students. The novelty of this work lies in its ability to anticipate students' needs regarding AI literacy, thereby enabling early and personalized interventions in the learning process.

Keywords: artificial intelligence; machine learning; neural networks; support vector machines.

Introducción

La inteligencia artificial (IA) se ha posicionado como una de las tecnologías disruptivas más influyentes en el ámbito educativo y científico del siglo XXI, destacando su potencial como tecnología transformadora capaz de personalizar el aprendizaje [5]. Su incorporación en los procesos de enseñanza-aprendizaje, investigación y toma de decisiones demanda que los futuros profesionales desarrollen competencias específicas en torno a su comprensión, aplicación crítica y ética [1, 2]. En este contexto, la alfabetización en inteligencia artificial (AI Literacy) se convierte en un componente clave para la formación universitaria, especialmente en carreras STEM, donde la IA se aplica de forma transversal en múltiples campos.

Estudios recientes han resaltado la necesidad de diseñar instrumentos válidos que permitan evaluar el nivel de alfabetización en IA en estudiantes universitarios y, a partir de ello, generar intervenciones pedagógicas contextualizadas [3, 4, 5]. Sin embargo, aún persisten desafíos metodológicos en la forma en que se mide esta alfabetización, ya que muchos instrumentos se basan exclusivamente en percepciones autoinformadas, sin una validación predictiva sobre su correspondencia con habilidades reales o potencial de desarrollo [6].

En este sentido, la aplicación de modelos predictivos basados en técnicas de machine learning, como redes neuronales artificiales (ANN) y máquinas de soporte vectorial (SVM), representa una alternativa innovadora para estimar el nivel de alfabetización en IA, a partir de patrones de respuesta. Estas técnicas han demostrado su efectividad en la predicción de variables educativas complejas, al permitir identificar relaciones no lineales entre factores latentes y comportamientos observables [7, 8].

Este estudio se enmarca en esta línea de innovación metodológica y tiene como objetivo aplicar técnicas de aprendizaje automático para predecir el nivel de alfabetización en IA en estudiantes universitarios que cursan asignaturas de estadística. La principal contribución de este trabajo radica en la posibilidad de anticipar las competencias de los estudiantes en IA.

Métodos

Se utilizó una metodología de entrenamiento de redes neuronales [9] y máquinas de soporte vectorial [10] para predecir el nivel de inteligencia artificial (NI-AI) en estudiantes universitarios de las distintas carreras en la Universidad Técnica de Manabí, Ecuador. Para las redes neuronales se utilizó el diseño arquitectónico y el algoritmo de aprendizaje supervisado. Para la máquina de soporte vectorial (SVM) se entrenó el modelo ajustando los hiperparámetros y se variaron los diferentes kernel (lineal, radial y polinomial).

El modelo predictivo se construyó a partir de cuatro variables principales que corresponden a las dimensiones de la alfabetización en inteligencia artificial evaluadas en el cuestionario: AAF (afectiva), ACD (conductual), ACN (cognitiva) y EIA (ética).

- AAF (Afectiva): refleja actitudes, motivación y disposición emocional hacia el aprendizaje y uso de la IA.
- ACD (Conductual): agrupa comportamientos observables y prácticas que los estudiantes desarrollan al aplicar la IA en contextos académicos.
- ACN (Cognitiva): incluye el conocimiento declarativo y procedimental sobre fundamentos, algoritmos y aplicaciones de la IA.
- EIA (Ética): integra percepciones y competencias relacionadas con la aplicación responsable, transparente y justa de la IA en entornos académicos y profesionales.

Estas dimensiones, al ser integradas en el modelo, permiten capturar una visión multidimensional de la alfabetización en IA, asegurando que no solo se evalúen conocimientos técnicos, sino también actitudes, prácticas y consideraciones éticas que inciden en la formación integral del estudiante.

Para la evaluación comparativa se consideraron dos enfoques de aprendizaje automático: máquinas de soporte vectorial (SVM) con núcleos lineal, radial y polinómico y redes neuronales multicapa (MLP) con diferentes configuraciones en el número de neuronas ocultas. El desempeño de cada modelo se valoró mediante un conjunto de métricas que incluyó el coeficiente de correlación de Spearman, el error absoluto medio (MAE), el error cuadrático medio (RMSE) y los tiempos de entrenamiento y predicción. Estas métricas permitieron analizar la capacidad predictiva, la estabilidad y la eficiencia computacional de los algoritmos bajo las mismas condiciones experimentales, a fin de

identificar el método más adecuado para la predicción del nivel de alfabetización en inteligencia artificial.

Cálculo del NI-AI

El cuestionario de alfabetización en IA utilizado en este estudio fue creado por [13]. El cuestionario se estructura en cuatro dimensiones de aprendizaje: afectiva, conductual, cognitiva y ética. Para ello, se utilizó la escala de Likert, donde 1 representa el nivel más bajo de alfabetización en IA y 5 el más alto. El cuestionario contiene 54 ítems distribuidos equitativamente en las cuatro dimensiones mencionadas.

Estimación del nivel de alfabetización en IA: Se construyó un índice integral para la estimación del nivel [3]. Esto se realizó mediante el uso de modas de variables y su importancia, con un índice (NA-AI)

$$NA - IA = \sum_{n=1}^4 1 P_n * M_n$$

donde:

$i \{i=1, 2, \dots, i-1\}$: i estudiantes analizados.

P_n : Peso específico para la variable n .

$NA-IA$: Uso del nivel de alfabetización en IA.

M_n : Moda calculada para E_n , m y para cada CD_n .

$D_n \{n=1, 2, \dots, 4\}$: n dimensión analizada del conjunto de dimensiones.

$E_{n,m} \{m=1, 2, \dots, l\}$: m ítems medidos dentro de la variable n , donde l representa el número total de elementos medidos dentro de cada variable n .

CD_n : Variable ordinal que evalúa los puntos categorizados para la dimensión n .

Resultados

La base de datos analizada estuvo conformada por 904 observaciones de estudiantes universitarios de carreras de ingeniería que cursaban asignaturas de estadística en la Universidad Técnica de Manabí. El rango de edad predominante fue de 19 a 25 años, con representación menor de estudiantes entre 17 y 18 años y un grupo reducido de mayores de 26 años. En términos de nivel de estudios, los participantes se distribuyeron principalmente entre los semestres intermedios y

avanzados (4.º a 8.º), lo cual contextualiza los hallazgos y explica la variabilidad encontrada en las predicciones del nivel de alfabetización en IA, dado que la progresión académica se asocia con mayor experiencia en el uso de tecnologías digitales y herramientas estadísticas.

El conjunto fue dividido en 678 observaciones de entrenamiento (75%) y 226 de prueba (25%), siguiendo un protocolo de muestreo estratificado con semilla aleatoria fija. Esta estrategia garantizó representatividad y comparabilidad entre fases del modelado. En paralelo, se aplicó validación cruzada con $K = 5$ pliegues, estratificados por cuantiles de ND, lo que aseguró homogeneidad en la distribución de la variable dependiente entre subconjuntos. La adopción de este esquema metodológico es consistente con las recomendaciones de Kuhn y Johnson [15] para estudios de predicción educativa.

Desempeño de máquinas de soporte vectorial (SVM)

El primer bloque de experimentación correspondió a la evaluación de SVM bajo tres kernels: lineal, radial (RBF) y polinómico. Los resultados de validación cruzada (Tabla 1) evidenciaron que SVM-RBF alcanzó el mejor desempeño global, con un $\rho = 0.9989$, MAE = 0.0548 y RMSE = 0.0657. Este resultado, acompañado de una desviación estándar mínima (RMSE_SD = 0.0047), confirma la estabilidad del modelo entre pliegues.

El kernel lineal mostró un rendimiento aceptable (RMSE = 0.0734), lo que indica que una relación parcialmente lineal está presente, pero insuficiente para representar la complejidad total de los datos. Por el contrario, el kernel polinómico presentó una degradación marcada (RMSE = 0.3754), lo que sugiere sobreajuste e ineficiencia para este dominio (tabla 1).

Tabla 1 - CV SVM — resumen por kernel

Modelo	Spearman_M	Spearman_SD	MAE_M	MAE_SD	RMSE_M	RMSE_SD
SVM_radial	0.9989	0.0006	0.0548	0.0061	0.0657	0.0047
SVM_lineal	0.9990	0.0005	0.0649	0.0032	0.0734	0.0023
SVM_polinómico	0.9755	0.0017	0.2967	0.0206	0.3754	0.0214

En cuanto al tiempo de cómputo (tabla 2), el kernel lineal fue el más eficiente (0.02 s), seguido del polinómico (0.45 s), mientras que el radial requirió mayor tiempo (0.65 s). Sin embargo, su coste adicional resulta marginal frente a la ganancia de precisión, situándolo como la mejor alternativa en términos de balance entre exactitud y eficiencia.

Tabla 2 - CV SVM — tiempos por kernel

Kernel	Fit_sec	Pred_sec	Total_sec
Lineal	0.02	0.00	0.02

APRENDIZAJE AUTOMÁTICO PARA LA PREDICCIÓN DEL NIVEL DE ALFABETIZACIÓN EN LA INTELIGENCIA ARTIFICIAL EN ESTUDIANTES UNIVERSITARIOS

Radial	0.53	0.12	0.65
Polinómico	0.38	0.07	0.45

Los hiperparámetros ganadores para SVM-RBF (cost = 10; gamma = 0.1/p) refuerzan la hipótesis de que no linealidades suaves explican mejor la relación entrada y salida en este problema (hipótesis avalada por el patrón junto a la diagonal en figura 2).

Desempeño de redes neuronales multicapa (MLP)

Los resultados (tabla 3) muestran que la MLP con 6 neuronas ocultas (h=6) ofreció el mejor compromiso, con RMSE = 0.0056, MAE = 0.0043 y correlación de $\rho \approx 0.9999$. Sin embargo, al incrementar el número de neuronas (h=10, 12, 16), el rendimiento se deterioró, aumentando el RMSE y la variabilidad entre pliegues. Este fenómeno indica que la muestra no soporta arquitecturas más complejas y que redes más grandes inducen suavizado excesivo y sobreajuste (tabla 3).

Tabla 3 - CV MLP — resumen por tamaño de capa oculta

Modelo	Spearman_M	Spearman_SD	MAE_M	MAE_SD	RMSE_M	RMSE_SD
MLP_h6	0.9999	0.0000	0.0043	0.0011	0.0056	0.0014
MLP_h10	0.9999	0.0001	0.0050	0.0017	0.0079	0.0028
MLP_h12	0.9999	0.0000	0.0050	0.0006	0.0092	0.0027
MLP_h16	0.9999	0.0000	0.0055	0.0015	0.0089	0.0034

En términos de coste de entrenamiento, la MLP con h=6 necesitó 6.87s, mientras que con h=16 el tiempo ascendió a 13.41s, aunque la predicción se mantiene inmediata (tabla 4). Estos valores sugieren que, a diferencia de SVM, las redes neuronales requieren un tiempo considerablemente mayor en fases de ajuste, lo que podría ser crítico en escenarios de reentrenamiento frecuente.

Tabla 4 - CV MLP — tiempos por configuración

Hidden	Fit_sec	Pred_sec	Total_sec
6	6.87	0.00	6.87
10	6.19	0.00	6.19
12	6.89	0.00	6.89
16	13.41	0.00	13.41

La figura 1 muestra la arquitectura de la red ganadora, donde se observa la convergencia tras 3003 iteraciones y un error final de 0.0064. La visualización de pesos evidencia la contribución diferenciada de las dimensiones afectiva, cognitiva, conductual y ética hacia la predicción del NAIAH.




Fig. 1 - Red neuronal multicapa con variables de predicción.

En el conjunto de prueba, tanto SVM-RBF como MLP(h=6) mostraron desempeños sobresalientes, con correlaciones cercanas a la perfección. No obstante, la comparación detallada (Tabla 5) evidencia que la red neuronal suaviza los valores extremos, mientras que SVM conserva mayor precisión en picos y rupturas.

Tabla 5 - Comparativa en el caso a caso (Real, Pred_SVM, Pred_MLP)

Modelo	Spearman	MAE	RMSE
SVM_best	0.999	0.0497	0.0602
MLP_best	1.000	0.0028	0.0046

En términos de eficiencia (tabla 6), SVM completó entrenamiento y predicción en 0.02 s, mientras que la MLP necesitó 0.95 s para el ajuste, confirmando el mayor coste de las redes.

Tabla 6 - Tiempos finales en prueba

Modelo	Fit_sec	Pred_sec	Total_sec
SVM_radial	0.02	0.00	0.02
MLP_h6	0.95	0.00	0.95

La inspección caso a caso (tabla 7) y las visualizaciones aportan información complementaria. En la figura 2 (dispersión Real vs. Predicho), los puntos SVM se alinean estrechamente con la diagonal, mientras que MLP muestra pequeñas desviaciones en extremos. La figura 3 (serie ordenada) revela que SVM reproduce con fidelidad los escalones, mientras MLP los suaviza. La figura 4 (boxplot de residuos) corrobora estas diferencias: ambos modelos tienen residuos centrados en cero, pero SVM presenta menor dispersión y colas más cortas, reforzando su ventaja en precisión puntual.

Tabla 7 - Comparativa en el caso a caso (Real, Pred_SVM Pred_MLP)

ID	Real	Est_SVM	Est_MLP
1	2.941	2.984	2.946
2	3.317	3.337	3.322
3	3.854	3.826	3.843
4	5.000	4.892	4.994

APRENDIZAJE AUTOMÁTICO PARA LA PREDICCIÓN DEL NIVEL DE ALFABETIZACIÓN EN LA INTELIGENCIA ARTIFICIAL EN ESTUDIANTES UNIVERSITARIOS

5	4.032	4.090	4.036
6	3.581	3.507	3.578
7	2.026	1.950	2.027
8	2.494	2.480	2.494
9	2.640	2.596	2.640
10	2.904	2.892	2.905
11	2.319	2.308	2.320
12	2.001	1.923	2.001
13	1.750	1.731	1.747
14	3.750	3.658	3.746
15	2.000	1.929	2.000
16	1.218	1.181	1.214
17	3.226	3.238	3.229
18	4.196	4.211	4.191
19	1.791	1.789	1.791
20	1.000	1.109	1.003
...	...	...	...
225	2.946	2.924	2.946
226	2.939	2.942	2.939

La figura 2 confirma gráficamente este hallazgo: los puntos estimados por SVM-RBF se alinean con gran precisión sobre la diagonal de referencia ($y = x$), evidenciando que la correlación reportada en los indicadores no es espuria sino robusta.




Fig. 2 - Dispersión Real vs. Predicho — SVM vs. MLP

En la figura 3, SVM reproduce con mayor fidelidad los escalones y rupturas, mientras que MLP suaviza transiciones; esta diferencia estructural explica la brecha de RMSE observada en tabla 5.




Fig. 3 - Serie ordenada — SVM vs. MLP

En la figura 4 ambos modelos muestran residuos centrados en cero; SVM presenta dispersión algo menor y menos valores extremos, alineado con su mejor desempeño en MAE/RMSE (ver tablas 5 y 6).




Fig. 4 - Boxplot de residuos en prueba (Pred – Real)

Los resultados confirman que ambos enfoques SVM y MLP poseen alta capacidad predictiva para estimar el nivel de alfabetización en IA. Sin embargo, existen diferencias estratégicas: SVM-RBF combina precisión con tiempos mínimos de cómputo, lo que lo convierte en la mejor opción para contextos operativos donde se requieran reentrenamientos frecuentes o recursos limitados. MLP ($h=6$) ofrece la ventaja de capturar relaciones complejas entre dimensiones y aportar interpretabilidad estructural, aunque penaliza la eficiencia y suaviza extremos.

El hecho de que todos los modelos alcanzaran $p > 0.99$ sugiere que el cuestionario NAIAH posee una estructura informativa robusta, validando su uso como instrumento confiable de evaluación. No obstante, las limitaciones deben señalarse: la muestra corresponde a un contexto universitario específico y aún no se integran variables sociodemográficas o motivacionales que podrían enriquecer el modelo.

Discusión

APRENDIZAJE AUTOMÁTICO PARA LA PREDICCIÓN DEL NIVEL DE ALFABETIZACIÓN EN LA INTELIGENCIA ARTIFICIAL EN ESTUDIANTES UNIVERSITARIOS

Los resultados obtenidos evidencian la alta capacidad predictiva de los modelos de aprendizaje automático para estimar el nivel de alfabetización en inteligencia artificial (NA-IAH) en estudiantes universitarios. En particular, el modelo SVM con kernel radial alcanzó un equilibrio notable entre precisión y estabilidad (tabla 1), superando tanto al kernel lineal como al polinómico. Este hallazgo coincide con investigaciones previas que destacan la robustez de los modelos SVM-RBF en contextos educativos y de predicción compleja, al capturar patrones no lineales de manera eficiente [11, 12]. Además, la baja desviación estándar del RMSE respalda su consistencia pliegue a pliegue, lo que refuerza su potencial como modelo de referencia en estudios similares.

Por otro lado, las redes neuronales multicapa (MLP) mostraron un comportamiento competitivo (tabla 3), aunque con un costo computacional mayor (tabla 4). El mejor desempeño se obtuvo con arquitecturas más compactas ($h=6$), mientras que configuraciones más profundas ($h=10, 12, 16$) tendieron a incrementar la variabilidad y el error cuadrático medio. Este patrón confirma lo reportado por estudios recientes sobre el riesgo de sobreajuste en redes neuronales con muestras de tamaño limitado [13, 14]. Asimismo, la alta correlación ordinal ($\rho \approx 0.9999$) refleja la capacidad de las MLP para preservar el orden relativo de los casos, aunque con ligeras limitaciones en la captura de valores extremos, como se observa en la figura 2.

Al comparar caso a caso (tabla 7), se identificó que SVM-RBF se ajusta mejor en escenarios de transiciones bruscas y valores máximos, mientras que la MLP tiende a suavizar los picos, lo que explica su mayor RMSE relativo. Esta diferencia se manifiesta también en la inspección gráfica: los puntos de SVM-RBF se alinean de manera más precisa con la diagonal $y=x$ (figura 2), mientras que MLP exhibe ligeras infraestimaciones en los extremos. Tales hallazgos coinciden con trabajos que resaltan la superioridad de SVM frente a MLP en dominios con estructuras de datos no lineales pero acotadas [9, 10].

En términos de tiempos de cómputo (tablas 2 y 6), ambos métodos resultan viables para contextos académicos, ya que los ajustes y predicciones se completaron en menos de un segundo. Sin embargo, la MLP requirió más tiempo de entrenamiento en comparación con SVM, lo cual puede ser crítico en escenarios donde se requieren reentrenamientos frecuentes o recursos computacionales limitados.

Esto está en línea con estudios que plantean la importancia de evaluar no solo la precisión de los modelos, sino también su costo operativo en contextos educativos [1, 2].

El análisis de importancia de las variables de entrada reveló que la dimensión cognitiva (ACN) y la conductual (ACD) tuvieron mayor peso en la predicción del nivel de alfabetización en IA, lo que sugiere que el conocimiento técnico y las prácticas aplicadas son los factores más determinantes en la competencia estudiada. En contraste, las dimensiones afectivas (AAF) y ética (EIA), aunque relevantes, mostraron una contribución relativamente menor, lo que indica que, si bien influyen en el desempeño, no determinan en igual medida el resultado global del modelo. Estos hallazgos coinciden con estudios previos que destacan la primacía de las habilidades cognitivas y prácticas en la alfabetización digital y en IA [5, 8, 16].

Finalmente, estos resultados reafirman la relevancia de utilizar modelos de machine learning para anticipar necesidades formativas en alfabetización en IA, lo que abre la posibilidad de diseñar intervenciones pedagógicas tempranas, personalizadas y basadas en datos. Este enfoque responde a los desafíos planteados en la literatura sobre la evaluación integral de la alfabetización en IA, donde se sugiere pasar de escalas autoinformadas a métodos predictivos validados empíricamente [5, 16, 17, 18]. En este sentido, la presente investigación contribuye a fortalecer las bases metodológicas para medir y predecir competencias digitales emergentes en educación superior.

Conclusiones

La presente investigación confirma que los modelos de aprendizaje automático constituyen una herramienta eficaz para predecir el nivel de alfabetización en inteligencia artificial (NA-IAH) en estudiantes universitarios. Entre las técnicas evaluadas, la máquina de soporte vectorial con kernel radial (SVM-RBF) se posiciona como la mejor alternativa metodológica, al combinar un desempeño superior en métricas de error (MAE y RMSE) con una alta estabilidad en validación cruzada y tiempos de cómputo mínimos [13, 14]. Este hallazgo coincide con trabajos previos que destacan la capacidad de SVM para capturar relaciones no lineales y su eficiencia en dominios educativos [9, 10].

Las redes neuronales multicapa (MLP), aunque competitivas en términos de correlación ordinal, mostraron limitaciones en la estimación de valores extremos y demandaron mayor tiempo de

entrenamiento. No obstante, su flexibilidad estructural sugiere un potencial considerable en escenarios con bases de datos más extensas y diversidad de predictores, lo que abre líneas de investigación futuras orientadas a explorar arquitecturas más profundas y métodos de regularización avanzados [11, 12].

Desde una perspectiva aplicada, los hallazgos refuerzan la utilidad de estas metodologías para la detección temprana de fortalezas y debilidades en la alfabetización en IA, contribuyendo al diseño de políticas educativas basadas en evidencia. En particular, la identificación precisa de casos críticos mediante SVM ofrece un recurso estratégico para orientar intervenciones pedagógicas diferenciadas, alineándose con la necesidad de preparar a los estudiantes para los retos que plantea la sociedad digital [1, 5, 16].

Finalmente, se reconoce como limitación el tamaño muestral y el alcance contextual de la base de datos analizada. En consecuencia, futuras investigaciones deberían extender el análisis a diferentes instituciones, contextos socioculturales y dimensiones de la alfabetización en IA, incorporando factores éticos, cognitivos y socioemocionales [4,7]. De este modo, será posible robustecer la validez externa de los modelos y avanzar hacia marcos híbridos que integren la capacidad local de ajuste de SVM con la flexibilidad estructural de las redes neuronales, generando sistemas predictivos más sólidos y escalables para la educación superior.

Referencias

1. Zawacki-Richter, O., et al., *Systematic review of research on artificial intelligence applications in higher education – where are the educators?* International Journal of Educational Technology in Higher Education, 2019. **16**(1): p. 39.
2. Wang, S., et al., *Artificial intelligence in education: A systematic literature review*. Expert Systems with Applications, 2024. **252**: p. 124167.
3. Chiu, T.K.F., *Future research recommendations for transforming higher education with generative AI*. Computers and Education: Artificial Intelligence, 2024. **6**.
4. Long, D. and B. Magerko. *What is AI literacy? Competencies and design considerations*. in *Proceedings of the 2020 CHI conference on human factors in computing systems*. 2020.
5. Ng DTK, Leung JCK, Chu SKW, Qiao M, Woo M, Ng O, et al. *Artificial intelligence (AI) literacy education in secondary*

- schools: A review*. Interact Learn Environ. 2023:1-21.
doi:10.1080/10494820.2023.2256946
6. Verduga- Alcivar, D.A.V., E.R. Roman-Cao, and N. Sablón-Cossío, (August 14) *Assessing artificial intelligence literacy in college students*. . 2024.
 7. San Martín, M.J.G., *¿Qué lugar ocupa la IA en las competencias digitales de los docentes?* Cuadernos de pedagogía, 2024(549): p. 19.
 8. Kong, S.C., W. Man-Yin Cheung, and G. Zhang, *Evaluation of an artificial intelligence literacy course for university students with diverse study backgrounds*. Computers and Education: Artificial Intelligence, 2021. **2**.
 9. Muñoz, E.G., et al., *Application of neural networks in predicting the level of integration in supply chains*. Journal of Industrial Engineering and Management, 2020. **13**(1): p. 120-132.
 10. Verduga Alcívar, D.A., E. Guillermo-Muñoz, and N. Sablón Cossío, *Support vector machines for predicting the level of integration in agri-food chains*. Ingeniería y Universidad: Engineering for Development Journal, 2023. **17**.
 11. Baashar, Y., et al., *Toward predicting student's academic performance using artificial neural networks (ANNs)*. Applied Sciences, 2022. **12**(3): p. 1289.
 12. Shou, Z., et al., *Predicting student performance in online learning: a multidimensional time-series data analysis approach*. Applied Sciences, 2024. **14**(6): p. 2522.
 13. Shdefat, A.Y., et al., *Optimizing HAR systems: comparative analysis of enhanced SVM and k-NN classifiers*. International Journal of Computational Intelligence Systems, 2024. **17**(1): p. 150.
 14. Shahzad, U., *A comparative analysis of artificial neural network and support vector machine for online transient stability prediction considering uncertainties*. Australian Journal of Electrical and Electronics Engineering, 2022. **19**(2): p. 101-116.
 15. Kuhn M, Johnson K. *Feature Engineering and Selection: A Practical Approach for Predictive Models*. Boca Raton: CRC Press; 2019.
 16. Biagini G. Assessing the assessments: *Toward a multidimensional approach to AI literacy*. Media Education. 2024;15(1):91-101.
 17. Chiu TKF. Future research recommendations for transforming higher education with generative AI. *Comput Educ Artif Intell*. 2024;6:100163. doi:10.1016/j.caeai.2023.100163
 18. Long D, Magerko B. What is AI literacy? Competencies and design considerations. In: Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems; 2020 Apr 25-30; Honolulu, HI, USA. New York: ACM; 2020. p. 1-16. doi:10.1145/3313831.3376727

Conflicto de interés

Los autores declaran que no hay conflicto de interés.

Contribución de cada autor:

Douglas Andrés Verduga Alcívar: El autor realizó la parte de introducción, resultados y conclusiones de la investigación en el objeto de estudio, evaluación de la capacidad productiva. Esto mediante la revisión y análisis de libros y artículos relacionados al tema de estudio, además realizó el cálculo e interpretación de resultados luego de haber aplicado la metodología respectiva, obteniendo así las conclusiones.

Eldis Román Cao: La autora contribuyó en la parte de: métodos y discusión de la investigación en el objeto de estudio, evaluación de la capacidad productiva. Esto mediante una metodología con un enfoque cuantitativo para obtener números reales de la empresa, en la discusión a través del análisis teórico y revisión de los resultados además colaboró en la organización e ideas de la investigación.

Neyfe Sablón Cossío: La autora contribuyó en la parte de: métodos y discusión de la investigación en el objeto de estudio, evaluación de la capacidad productiva. Esto mediante una metodología con un enfoque cuantitativo para obtener números reales de la empresa, en la discusión a través del análisis teórico y revisión de los resultados además colaboró en la organización e ideas de la investigación.