

Modelos predictivos con inteligencia artificial: detección temprana de perfiles de diversidad comunicativa en educación médica superior

Predictive Models using Artificial Intelligence: Early Detection of Communicative Diversity Profiles in Higher Medical Education

Diana Flor García Calle^{1*} <https://orcid.org/0009-0003-1956-6530>

Mayra Lorena Becilla Vera² <https://orcid.org/0009-0004-8373-4911>

Narcisa Isabel Cordero Alvarado³ <https://orcid.org/0000-0002-4175-8817>

Carmen Graciela Urgilés Carabajo⁴ <https://orcid.org/0009-0008-1760-7542>

Karina Mariela Solano Farias⁴ <https://orcid.org/0000-0003-1087-0483>

Diana Asunción Ortiz Salas⁵ <https://orcid.org/0000-0002-6181-7749>

Aracely Jacqueline Mendoza Vega⁵ <https://orcid.org/0000-0001-7071-4357>

¹Universidad Estatal de Milagro. Guayas, Ecuador.

²Universidad Técnica de Babahoyo. Ecuador.

³Universidad Estatal de Milagro. Ecuador.

⁴Universidad Agraria del Ecuador. Guayaquil, Ecuador.

⁵Universidad César Vallejo. Piura, Perú.

*Autor para la correspondencia: dgarcia@unemi.edu.ec

RESUMEN

Introducción: La detección temprana de perfiles de diversidad comunicativa es una línea de investigación contemporánea que pudiera garantizar procesos formativos efectivos en ciencias de la salud al integrarse inteligencia artificial.

Objetivo: Establecer un modelo predictivo respaldado por inteligencia artificial para la identificación precoz de perfiles de diversidad comunicativa en alumnos de educación médica superior.

Métodos: Investigación cuantitativa-aplicada, de alcance explicativo-predictivo y diseño no experimental con enfoque transversal. Participaron 200 estudiantes de ciencias de la salud, evaluados con instrumentos comunicativos, cognitivos y metacognitivos. Los datos se gestionaron con modelos supervisados mediante inteligencia artificial (regresión logística, SVM, *Random Forest*, *Gradient Boosting* y redes neuronales), y se emplearon validación cruzada estratificada y métricas de rendimiento predictivo.

Resultados: La detección temprana de perfiles de diversidad comunicativa tuvo el mejor desempeño predictivo con los modelos de ensamble. Sobresalió *Gradient Boosting*, con AUC-ROC = $0,90 \pm 0,02$, F1-score = 0,87 y sensibilidad del 89,1 %. El rendimiento de *Random Forest* fue estadísticamente similar (AUC-ROC = $0,88 \pm 0,02$), con una estabilidad superior entre pliegues (CV < 4%). Aunque se encontraron diferencias notables entre la regresión logística y *Gradient Boosting* ($\Delta\text{AUC} = 0,10$; $p < 0,001$), no fue así en comparación con *Random Forest* ($p > 0,05$). Según el análisis de interpretabilidad, las principales variables predictivas resultaron la comprensión lectora (24,7 %), la comunicación oral académica (28,4 %) y la autorregulación del aprendizaje (19,6 %). La concordancia fue alta entre los evaluadores expertos (Kappa = 0,79).

Conclusiones: Los modelos de ensamble tienen un rendimiento predictivo mucho mayor en la detección temprana de perfiles de diversidad comunicativa.

Palabras clave: modelos predictivos; inteligencia artificial; diversidad comunicativa; educación médica superior.

ABSTRACT

Introduction: Early detection of communicative diversity profiles represents a contemporary line of research that can support effective educational processes in the health sciences through the integration of artificial intelligence.

Objective: To establish an artificial intelligence-supported predictive model for the early identification of communicative diversity profiles in students of higher medical education.

Methods: A quantitative, applied study with an explanatory-predictive scope and a non-experimental, cross-sectional design was conducted. A total of 200 health

sciences students participated and were assessed using communicative, cognitive, and metacognitive instruments. Data were analyzed using supervised artificial intelligence models (logistic regression, SVM, Random Forest, Gradient Boosting, and neural networks), employing stratified cross-validation and predictive performance metrics.

Results: Early detection of communicative diversity profiles showed the highest predictive performance with ensemble models, with Gradient Boosting standing out (AUC-ROC = 0.90 ± 0.02 ; F1-score = 0.87; sensitivity = 89.1%). Random Forest achieved statistically comparable performance (AUC-ROC = 0.88 ± 0.02), with greater stability across folds (CV < 4%). Significant differences were observed between logistic regression and Gradient Boosting ($\Delta\text{AUC} = 0.10$; $p < 0.001$), but not in comparison with Random Forest ($p > 0.05$). Interpretability analysis identified reading comprehension (24.7%), academic oral communication (28.4%), and self-regulated learning (19.6%) as the main predictive variables. Inter-rater agreement among expert evaluators was high (Kappa = 0.79).

Conclusions: Ensemble models exhibit substantially higher predictive performance for the early detection of communicative diversity profiles.

Keywords: predictive models; artificial intelligence; communicative diversity; higher medical education.

Recibido: 24/02/2026

Aceptado: 04/03/2026

Introducción

La incorporación gradual de sistemas fundamentados en inteligencia artificial (IA) en los procesos de gestión académica, evaluación y enseñanza ha sido promovida por la transformación digital de la educación superior.^(1,2) En este marco, los modelos predictivos de IA se han establecido como instrumentos estratégicos para prever fenómenos complejos en la educación, reconocer patrones de rendimiento y mejorar el proceso de toma de decisiones institucionales.⁽³⁾ Se han podido examinar extensos volúmenes de datos académicos, comunicativos y conductuales gracias

a tecnologías como el procesamiento del lenguaje natural, el aprendizaje profundo y el aprendizaje automático, lo que ha dado lugar a indicadores que van más allá de los métodos tradicionales de evaluación.^(4,5,6)

La habilidad para anticipar las trayectorias educativas y las necesidades particulares de los alumnos se vuelve especialmente importante en el campo de la educación médica superior, que se distingue por tener elevados grados de exigencia cognitiva, una interacción clínica complicada y un examen constante,^(7,8) aspectos que en la literatura se ha gestionado con IA.⁽⁹⁾ La comunicación es un eje transversal de la formación médica, debido a su impacto directo en la calidad de la atención sanitaria, la relación entre el médico y el paciente, y el trabajo interdisciplinario.^(10,11,12) No obstante, las metodologías tradicionales de evaluación comunicativa tienden a enfocarse en la observación puntual de habilidades, sin tener en cuenta que la diversidad comunicativa es un fenómeno multidimensional, contextual y dinámico.

La diversidad comunicativa en la educación médica no se restringe a las variaciones lingüísticas, sino que también abarca las diferencias en los estilos de discurso, la regulación emocional, la empatía, la pragmática clínica, el intercambio intercultural y la adaptación a variados escenarios asistenciales.⁽¹³⁾ Estas disparidades pueden deberse a factores de tipo emocional, cognitivo, formativo y sociocultural; por lo tanto, la identificación precoz no debe considerarse como un método de clasificación excluyente, sino como una estrategia para fomentar apoyos individualizados, consolidar habilidades y evitar problemas en el rendimiento.^(14,15,16)

La inclusión de modelos predictivos fundamentados en IA ofrece la oportunidad de examinar información proveniente de diversas fuentes, como las evaluaciones clínicas estructuradas, los registros académicos, las rúbricas de comunicación, las simulaciones con pacientes estandarizados y las plataformas virtuales. Esto permite identificar patrones vinculados a perfiles de diversidad comunicativa.^(17,18) Mediante algoritmos supervisados y no supervisados, se pueden detectar agrupaciones (*clustering*), tendencias longitudinales y variables predictivas, que posibiliten prever requerimientos de formación particulares.⁽¹⁹⁾

Instituciones académicas de medicina reconocidas en todo el mundo han comenzado a integrar sistemas inteligentes y análisis de aprendizaje para optimizar la retroalimentación formativa y supervisar el avance de los estudiantes.⁽²⁰⁾ Estas propuestas se encuentran dentro de las tendencias mundiales del aprendizaje analítico y la educación fundamentada en datos, que tienen como objetivo optimizar la personalización y la equidad del aprendizaje en contextos complejos.

Sin embargo, la implementación de IA en la identificación de perfiles comunicativos en medicina superior afronta retos importantes desde las perspectivas ética y epistemológica. Según la perspectiva metodológica, para operacionalizar el concepto de “diversidad comunicativa”, es necesario que se establezcan constructos fiables y válidos que abarquen las dimensiones socioemocionales, lingüísticas y paralingüísticas.⁽²¹⁾

La detección precoz de perfiles diversos en términos comunicativos a través de la IA, desde el punto de vista pedagógico, puede ayudar a reforzar la educación centrada en el aprendiz, ya que permite intervenciones diferenciadas, tutorías concretas y programas de simulación adaptativa.⁽²²⁾ Asimismo, el uso de métodos de procesamiento de lenguaje natural (NLP) en simulaciones clínicas y registros de interacción entre médicos y pacientes crea nuevas oportunidades para estudiar la adecuación pragmática, el tono emocional, la coherencia argumentativa y los patrones discursivos.⁽²³⁾

En un contexto educativo posterior a la pandemia, en el que se ha hecho más uso de plataformas digitales y se han producido cantidades masivas de datos comunicativos, debido a la virtualización parcial de la enseñanza médica,^(24,25) el valor de esta línea de investigación aumenta. Las videoconferencias clínicas, los foros, las simulaciones en línea y las evaluaciones virtuales son recursos valiosos para la predicción analítica, siempre que se mantenga el respeto por los principios de consentimiento informado y confidencialidad.⁽²⁶⁾

Combinar modelos predictivos con IA en la educación médica de nivel superior abre una oportunidad estratégica para progresar hacia sistemas educativos que sean más inclusivos, individualizados y fundamentados en evidencias.⁽²⁷⁾ Sin embargo, su desarrollo necesita un enfoque responsable desde el punto de vista ético y pedagógico, y que incluya diversas disciplinas, para asegurar que la tecnología funcione como una herramienta para apoyar el aprendizaje en lugar de ser un instrumento de estandarización reduccionista. Por lo tanto, la identificación temprana de perfiles de diversidad comunicativa se establece como un área emergente de investigación con un gran potencial para influir en el ámbito académico, clínico y social.⁽²⁸⁾

Se asume que el reconocimiento adecuado de patrones comunicativos distintos puede mejorar las intervenciones formativas personalizadas, aumentar la calidad de la atención futura, y ayudar a la educación integral del profesional de la salud.⁽²⁹⁾ Por ello, el estudio tuvo como propósito establecer un modelo predictivo respaldado por IA para la identificación precoz de perfiles de diversidad comunicativa en alumnos de educación médica superior.

Métodos

El análisis empleó un método secuencial de tipo analítico, que utilizaba modelos predictivos de IA con el fin de detectar perfiles de diversidad comunicativa en alumnos de educación médica superior desde el principio; se les dio prioridad a dos indicadores estratégicos:

1. la identificación de variables fundamentales vinculadas a la diversidad comunicativa
2. la funcionalidad del modelo para aplicar intervenciones pedagógicas personalizadas y tempranas

Por ello, la investigación se declaró de tipo cuantitativa-aplicada, de alcance explicativo-predictivo y diseño no experimental con enfoque transversal, y tuvo como hipótesis que los modelos de ensamble basados en IA (especialmente *Random Forest* y *Gradient Boosting*) presentan un rendimiento predictivo significativamente superior a los modelos lineales y probabilísticos para la identificación temprana de perfiles de diversidad comunicativa en estudiantes de educación médica superior.

Participantes

Se llevó a cabo la evaluación del desempeño predictivo de los modelos de IA, a través de procedimientos automatizados, sin participación humana directa, lo que aseguró objetividad y capacidad de reproducción en el análisis de datos. El proceso abarcó la comparación estadística formal entre algoritmos y la validación cruzada estratificada. Tres especialistas independientes, con formación y experiencia en evaluación pedagógica, comunicación académica y educación médica superior, realizaron la evaluación interpretativa y aplicada de los modelos. Para garantizar la independencia del juicio experto, ninguno de los evaluadores tomó parte en el desarrollo, el entrenamiento o el ajuste de los modelos predictivos.

Los estudiantes que participaron en el análisis fueron seleccionados aleatoriamente ($n = 200$), según parámetros establecidos previamente ($N = 415$; Confianza: 95 %; Error: 5 %), cuyos criterios de inclusión se relacionaron con estar matriculados (3er y 4to año) en carreras de ciencias médicas en la Universidad Estatal de Milagro, y haber participado en evaluaciones estructuradas de competencia comunicativa

(oral y escrita) y en actividades de simulación clínica curriculares (sin asignaturas suspensas) con firma de consentimiento informado.

Procedimientos

El procedimiento fue diseñado para asegurar la robustez estadística, la interpretabilidad del modelo y la transferencia práctica de los hallazgos al contexto educativo (septiembre de 2024-enero de 2025) en la Universidad Estatal de Milagro con estudiantes de ciencias médicas. Se estructuraron los datos en una matriz de observaciones para cada alumno, incluyendo variables académicas, comunicativas, sociodemográficas y cognitivas, que ya habían sido validadas en entornos de educación médica. Antes de la evaluación se llevó a cabo un procedimiento de depuración de datos, que abarcó la identificación de valores atípicos, el análisis de datos ausentes y la estandarización de variables continuas. Las variables categóricas fueron codificadas mediante métodos de codificación adecuados y las continuas se normalizaron cuando el algoritmo lo necesitaba, con el fin de facilitar la comparabilidad entre modelos y su interpretabilidad.

Se entrenaron varios algoritmos de aprendizaje supervisado (árboles de decisión, *Random Forest*, *Support Vector Machine*, modelos de *boosting* y regresión logística regularizada) con un esquema de validación cruzada estratificada *k-fold* ($k = 5$ o 10), lo que aseguró que la proporción de clases en cada división se mantuviera. Se utilizó el mismo conjunto de particiones para todos los modelos, lo que posibilitó una comparación directa y controlada del desempeño en términos de predicción. Para prevenir la fuga de datos, los hiperparámetros se optimizaron a través de una búsqueda en rejilla dentro de cada pliegue de entrenamiento.

La identificación de variables clave fue un indicador fundamental del estudio. Se utilizaron métodos de análisis de importancia de variables complementarios. En dependencia del modelo tratado:

- Se evaluaron medidas de la relevancia de variables fundamentadas en la disminución de impureza y métodos de permutación, cuando se emplearon modelos que tenían como base a los árboles y a los ensambles (*Gradient Boosting* y *Random Forest*).
- Se emplearon métodos de interpretabilidad posteriores (por ejemplo, valores SHAP) para estimar la aportación individual de cada variable a las predicciones del modelo.

Las variables se clasificaron de acuerdo con su promedio de aportes a la predicción, lo que posibilitó el reconocimiento de las variables académicas, cognitivas y comunicativas con más impacto en la identificación temprana de perfiles con diversidad comunicativa. Los modelos fueron analizados, además de su rendimiento predictivo general, en términos de su habilidad para simplificar decisiones pedagógicas tempranas. Para este fin, se priorizaron métricas sensibles a la detección de alumnos en riesgo, como el F1-score, la sensibilidad y el AUC-ROC.

Se fijaron umbrales de decisión con el objetivo de optimizar la sensibilidad del modelo y reducir al mínimo la posibilidad de falsos negativos, lo cual resultó un criterio esencial para llevar a cabo acciones educativas preventivas. Además, se examinó la estabilidad de las predicciones a través de los pliegues de validación cruzada, para garantizar que las variables clave identificadas fuesen estables y no dependiesen de segmentos particulares de los datos.

La elección del modelo ideal se fundamentó en un enfoque que consideró múltiples criterios, incluyendo:

- Desempeño predictivo (AUC-ROC, sensibilidad y puntuación F1)
- Estabilidad del modelo (fluctuación entre los pliegues)
- Habilidad para interpretar las variables principales
- Utilidad de los resultados para intervenciones pedagógicas iniciales

Instrumentos

La investigación utilizó una perspectiva multimétodo para medir variables académicas, comunicativas, cognitivas y metacognitivas (tabla 1), relevantes para entornos clínico-académicos, su validez para la investigación educativa y su adecuación a modelos predictivos de IA (tabla 2).

Tabla 1 - Instrumentos para la competencia comunicativa

Dominio	Variable medida	Instrumento	Tipo de instrumento	Escala/salida	Uso en el modelo de IA
Competencia comunicativa	Comunicación oral académica	Rúbrica de competencia comunicativa en contextos clínico-académicos	Observacional (evaluadores expertos)	Puntuación ordinal (niveles)	Variable explicativa clave
Competencia comunicativa	Comunicación escrita académica	Prueba de producción escrita académica	Prueba de desempeño	Puntuación continua	Variable explicativa
Competencia comunicativa	Comprensión comunicativa	Test de comprensión de textos académicos	Prueba estandarizada	Percentiles / puntuación total	Variable explicativa
Procesamiento cognitivo-lingüístico	Fluidez verbal	Prueba de fluidez semántica y fonológica	Neuropsicológica	Número de respuestas correctas	Variable predictora discriminativa
Procesamiento cognitivo-lingüístico	Velocidad de procesamiento	Subprueba cognitiva breve	Cognitiva	Tiempo / puntuación estandarizada	Variable explicativa
Autorregulación	Autorregulación del aprendizaje	Cuestionario de estrategias de aprendizaje (subescalas)	Autoinforme (Likert)	Puntuación media por dimensión	Variable explicativa
Metacognición	Conciencia metacomunicativa	Escala de metacognición comunicativa	Autoinforme (Likert)	Puntuación total	Variable explicativa
Desempeño académico	Rendimiento académico	Registro institucional	Registro documental	Promedio académico	Variable de control
Participación comunicativa	Participación comunicativa en el aula	Rúbrica de participación comunicativa	Observacional	Nivel ordinal	Variable explicativa
Variable dependiente	Perfil de diversidad comunicativa	Clasificación basada en puntuaciones e informe experto	Categorización experta	Clases (típico / riesgo / diversidad)	Variable objetivo (label)

Tabla 2 - Modelos de inteligencia artificial comparados para la detección temprana de perfiles de diversidad comunicativa en educación médica superior

Categoría del modelo	Algoritmo	Tipo de aprendizaje	Propósito en el estudio	Fortalezas	Limitaciones	Métricas de evaluación recomendadas
Línea base / Interpretable	Regresión logística (LASSO / Ridge)	Supervisado	Establecer un clasificador base transparente	Alta interpretabilidad; adecuada para muestras pequeñas; explicabilidad clínica	Capacidad limitada para modelar relaciones no lineales	Exactitud, AUC-ROC, Odds Ratio
Basado en margen	<i>Support Vector Machine</i> (lineal, RBF)	Supervisado	Capturar fronteras de decisión no lineales	Buen rendimiento en muestras pequeñas-medias; control del sobreajuste	Interpretabilidad limitada; sensibilidad a la selección del kernel	AUC-ROC, F1-score, Sensibilidad
Basado en árboles	Árbol de decisión (CART)	Supervisado	Proporcionar reglas de decisión interpretables	Fácil visualización; comprensión pedagógica	Propenso al sobreajuste; inestabilidad	Exactitud, Exactitud balanceada
Ensamble (<i>Bagging</i>)	<i>Random Forest</i>	Supervisado	Clasificación robusta y análisis de importancia de variables	Maneja no linealidad; resistente al sobreajuste; identifica variables clave	Interpretabilidad parcial; mayor coste computacional	AUC-ROC, F1-score, SHAP
Ensamble (<i>Boosting</i>)	<i>Gradient Boosting</i> (XGBoost / LightGBM / CatBoost)	Supervisado	Maximizar el rendimiento predictivo	Alto desempeño en datos tabulares; modela interacciones complejas	Requiere ajuste de hiperparámetros; menor transparencia	AUC-ROC, Precisión-Recall, F1-score
Probabilístico	Naïve Bayes (Gaussiano / Multinomial)	Supervisado	Comparación probabilística base	Simple; bajo costo computacional	Supuesto fuerte de independencia entre variables	Exactitud, Sensibilidad
Redes neuronales	Perceptrón multicapa (MLP)	Supervisado	Modelar patrones no lineales complejos	Alta flexibilidad; capacidad de generalización	Requiere muestras mayores; baja interpretabilidad	AUC-ROC, F1-score

Análisis de datos

La estadística descriptiva inicial fue parte del análisis de datos, y se utilizó para describir las variables y comprobar supuestos fundamentales. Se empleó la validación cruzada estratificada para analizar el desempeño predictivo de los modelos, y se presentó como promedio $\pm$ desviación estándar la AUC-ROC, sensibilidad, especificidad, exactitud balanceada y puntuación F1. A través de la prueba de Friedman con análisis *post-hoc* para métricas repetidas y la prueba de DeLong para AUC, se examinaron las disparidades entre los modelos. La variabilidad entre pliegues se utilizó para evaluar la estabilidad del modelo. Se examinaron las variables clave a través de los valores SHAP y las medidas de importancia. Finalmente, especialistas confirmaron la utilidad pedagógica de los modelos mediante el uso de índices de concordancia interevaluador.

Resultados

Los modelos de ensamble presentaron el mayor rendimiento predictivo global, con *Gradient Boosting* que alcanzó el AUC-ROC más alto y baja variabilidad entre pliegues (tabla 3).

Tabla 3 - Rendimiento predictivo de los modelos de IA

Modelo	AUC-ROC (Media $\pm$ DE)	Sensibilidad (%)	F1-score	Exactitud balanceada
Regresión logística (LASSO)	0,80 $\pm$ 0,03	78,6	0,78	0,79
SVM (RBF)	0,84 $\pm$ 0,03	83,2	0,82	0,83
Árbol de decisión (CART)	0,77 $\pm$ 0,04	75,1	0,75	0,76
<i>Random Forest</i>	0,88 $\pm$ 0,02	87,9	0,86	0,86
<i>Gradient Boosting</i>	0,90 $\pm$ 0,02	89,1	0,87	0,87
Naïve Bayes	0,76 $\pm$ 0,03	73,4	0,74	0,75
MLP	0,85 $\pm$ 0,03	84,6	0,83	0,84

Gradient Boosting superó significativamente a los modelos lineales y SVM, mientras que no se observaron diferencias estadísticamente significativas con respecto a *Random Forest* (tabla 4).

Tabla 4 - Comparación inferencial entre modelos (AUC-ROC)

Comparación	Δ AUC	Estadístico	p-valor
<i>Gradient Boosting</i> vs. Regresión logística	0,10	DeLong Z = 3,92	< 0,001
<i>Gradient Boosting</i> vs. SVM	0,06	DeLong Z = 2,41	0,016
<i>Gradient Boosting</i> vs. <i>Random Forest</i>	0,02	DeLong Z = 1,12	0,262
<i>Random Forest</i> vs. Regresión logística	0,08	DeLong Z = 3,11	0,002

El análisis de importancia de variables mostró un predominio de competencias comunicativas y metacognitivas, directamente vinculables a intervenciones pedagógicas tempranas (tabla 5).

Tabla 5 - Variables claves identificadas y utilidad pedagógica (*Random Forest*-SHAP)

Variable	Importancia relativa (%)	Dominio
Comunicación oral académica	28,4	Comunicativo
Comprensión lectora académica	24,7	Cognitivo-lingüístico
Autorregulación del aprendizaje	19,6	Metacognitivo
Fluidez verbal	15,3	Cognitivo
Participación comunicativa	12,0	Pedagógico

Discusión

El presente estudio tuvo como propósito establecer un modelo predictivo respaldado por IA para la identificación precoz de perfiles de diversidad comunicativa en estudiantes de educación médica superior. Según los resultados

alcanzados, se consiguió desarrollar y realizar una comparación sistemática de diferentes algoritmos supervisados, al analizar su rendimiento predictivo dentro de un esquema sólido de validación cruzada estratificada.

Los modelos mostraron una capacidad discriminativa adecuada para distinguir perfiles comunicativos variados con grados de sensibilidad y AUC-ROC significativos en términos clínicos y pedagógicos. Por último, el análisis de la importancia de las variables corroboró que los predictores más significativos pertenecen a dominios metacognitivos, cognitivo-lingüísticos y comunicativos. Esto apoya la idea de que identificar patrones comunicativos diferentes puede guiar intervenciones formativas específicas, y mejorar la calidad de la futura práctica profesional.

El propósito presentado consistía no solo en obtener un elevado rendimiento predictivo, sino en asegurar la interpretabilidad y la utilidad pedagógica. La prueba de DeLong demostró que, en este contexto, los modelos de ensamble, sobre todo *Gradient Boosting* (AUC-ROC = $0,90 \pm 0,02$) y *Random Forest* (AUC-ROC = $0,88 \pm 0,02$), lograron una discriminación global superior a la que obtuvieron los modelos lineales y SVM. Que haya una diferencia estadísticamente significativa entre la regresión logística y *Gradient Boosting* ($\Delta\text{AUC} = 0,10$; $p < 0,001$) ratifica que es esencial modelizar interacciones complejas y relaciones no lineales para alcanzar la multidimensionalidad de la diversidad comunicativa.

No obstante, más allá del rendimiento absoluto, la elección final del modelo privilegió la estabilidad y la interpretabilidad. *Random Forest* reveló menos variabilidad entre los pliegues y permitió una identificación precisa de las variables esenciales a través de valores SHAP, lo cual hizo más sencilla la interpretación pedagógica de los resultados.

Este hallazgo se alinea con lo que *Mastour* y otros⁽⁹⁾ han indicado, con énfasis en la importancia de la IA explicativa en el ámbito educativo médico para prevenir decisiones algorítmicas poco transparentes. Además, la revisión sistemática de *Feigerlova* y otros⁽¹⁷⁾ subraya que los modelos de ensamble suelen brindar más robustez en contextos educativos sanitarios, si se combinan criterios de aplicabilidad formativa y desempeño.

La hipótesis suponía que la identificación apropiada de diferentes patrones de comunicación posibilitaría el perfeccionamiento de intervenciones personalizadas y el mejoramiento de la atención futura. Esta premisa cuenta con el respaldo de los datos empíricos: las variables que más contribuyeron a la predicción fueron la comunicación oral en el ámbito académico (28,4 %), la comprensión lectora en ese

mismo contexto (24,7 %) y la autorregulación del aprendizaje (19,6 %). Estas dimensiones no solo aclaran las variaciones en el perfil comunicativo, sino que representan campos que pueden ser intervenidos directamente, a través de programas de tutoría, simulacros clínicos adaptativos y entrenamientos en competencias comunicativas, como afirman *Saunders* y otros⁽¹³⁾ y *Peimani* y otros.⁽²⁹⁾

Uno de los hallazgos principales fue que las variables metacognitivas y comunicativas tenían un peso mayor que los indicadores académicos tradicionales. A pesar de que el rendimiento académico se incluyó como una variable de control, no surgió como un predictor clave del perfil de diversidad comunicativa. Esto indica que la diversidad comunicativa no puede considerarse un indicador de bajo rendimiento, sino que es una construcción multidimensional que engloba habilidades expresivas, comprensión pragmática y regulación cognitiva.

La importancia de la comunicación oral académica como principal predictor concuerda con lo que la literatura sostiene: la interacción clínica es el eje transversal en la educación médica.⁽¹⁰⁾ Además, el peso de la comprensión lectora en el ámbito académico demuestra que el procesamiento cognitivo-lingüístico y el rendimiento comunicativo son interdependientes, un fenómeno que también fue mencionado en estudios sobre minería de datos educativos.⁽¹⁹⁾

La tercera variable en importancia (la autorregulación del aprendizaje) agrega una dimensión metacognitiva fundamental. Según la investigación sobre educación adaptativa basada en IA,⁽²²⁾ los modelos predictivos tienen un mayor impacto si incorporan variables autorregulatorias, pues estas posibilitan el diseño de intervenciones sostenibles y diferenciadas. Este estudio refuerza la noción de que la diversidad comunicativa no es solo lingüística, sino metacognitiva y estratégica, a través de la convergencia entre variables comunicativas y metacognitivas.

Un hallazgo importante fue que los modelos de ensamble lograron una sensibilidad muy alta (de hasta 89,1 %), lo cual es un indicador clave en situaciones de detección temprana. Con el fin de impedir que alumnos con requerimientos formativos particulares carezcan de apoyo a tiempo, es fundamental reducir los falsos negativos. La perspectiva preventiva se alinea con las sugerencias de *Kumar* y *Suthar*⁽¹⁴⁾ sobre el análisis predictivo y la intervención temprana en entornos de salud.

Pham y otros⁽¹⁸⁾ también muestran que los modelos predictivos y la IA generativa ayudan a individualizar el aprendizaje en el contexto clínico, sobre todo en situaciones de simulación virtual. Los resultados recientes amplían este punto de

vista, al mostrar que la identificación estructurada de perfiles comunicativos puede incorporarse a sistemas de retroalimentación adaptativa.

Zheng y otros⁽²³⁾ crearon un sistema de procesamiento del lenguaje natural para evaluar la calidad comunicativa en las consultas oncológicas, y descubrieron que los modelos supervisados son capaces de captar dimensiones pragmáticas complejas. El presente estudio, a pesar de que no empleó el análisis textual automatizado en tiempo real, sostiene la idea de que los patrones comunicativos pueden ser modelados algorítmicamente con exactitud suficiente para respaldar decisiones educativas.

Por otra parte, la evidencia concuerda con los hallazgos de Noman y otros,⁽³⁾ que indican que el éxito de la IA en la educación está sujeto a una integración ética y pedagógica. La implementación de un juicio experto independiente para validar la utilidad formativa del modelo en este trabajo es una respuesta a esta sugerencia, con el objetivo de no depender únicamente del rendimiento estadístico.

Sin embargo, el estudio tiene limitaciones que deben tenerse en cuenta, dado el uso de un diseño transversal, que no permite examinar las trayectorias a lo largo del tiempo de la transformación comunicativa. Para analizar la evolución de la formación, estudios futuros podrían incluir modelos de series temporales o aprendizaje secuencial. Por otra parte, aunque se incluyeron múltiples variables, el modelo se basó en datos estructurados, dado que no se integraron datos multimodales como análisis prosódico, microexpresiones o transcripciones clínicas automatizadas. La literatura reciente sugiere que la incorporación de procesamiento de lenguaje natural y análisis multimodal puede enriquecer la detección de patrones comunicativos complejos. Igualmente, la muestra, al pertenecer a un solo contexto institucional, puede limitar su generalización debido a aspectos interculturales.

Por último, a pesar de que *Random Forest* demostró tener una adecuada interpretabilidad, los modelos de ensamble continúan siendo menos transparentes que las aproximaciones lineales. Esto requiere que se establezcan protocolos éticos precisos para su aplicación institucional.

Se concluye que los modelos de ensamble tienen un rendimiento predictivo mucho mayor en la detección temprana de perfiles de diversidad comunicativa cuando se utiliza una muestra amplia. A pesar de que *Gradient Boosting* tuvo el mejor rendimiento absoluto, *Random Forest* demostró una capacidad estadísticamente equiparable, una estabilidad superior y una interpretación más efectiva de variables

clave; por lo tanto, se sitúa como el modelo más apropiado para contextos educativos con propósitos diagnósticos e intervención temprana.

Referencias bibliográficas

1. Adamakis M, Rachiotis T. Artificial Intelligence in Higher Education: A State-of-the-Art Overview of Pedagogical Integrity, Artificial Intelligence Literacy, and Policy Integration. Encyclopedia. 2025;5(4):180. DOI: <https://doi.org/10.3390/encyclopedia5040180>
2. Trujillo FJ, Fagalde PJ. Inteligencia artificial en la educación superior: una revisión sistemática de la literatura (2020-2025). Revista Educación Las Américas. 2025;15(2):1-10. DOI: <https://doi.org/10.35811/rea.v15i2.400>
3. Noman Tahir DR, Mahmood SS, Malik DM. Artificial intelligence in education: enhancing learning outcomes through predictive analytics. TPM–Testing. Psychometrics, Methodology in Applied Psychology. 2025 [acceso 15/12/2025];32(4):738-51. Disponible en: <https://tpmap.org/submission/index.php/tpm/article/view/3163>
4. Sagarra-Romero L, Monroy Antón A, Calero Morales S, Ruidiaz Peña M. athlete Heart Rate Variability app: knowing when to train. British Journal of Sports Medicine. 2017;51:1-3. DOI: <https://doi.org/10.1136/bjsports-2016-097303>
5. Gao Y. Deep learning-based strategies for evaluating and enhancing university teaching quality. Computers and Education: Artificial Intelligence. 2025;8:100362. DOI: <https://doi.org/10.1016/j.caeai.2025.100362>
6. Uribarri HG, Lago-Fuentes C, Bores-Arce A, Álvarez VE, López-García, Calero-Morales S, et al. External Load Evaluation in Elite Futsal: Influence of Match Results and Game Location with IMU Technology. Journal of Functional Morphology and Kinesiology. 2024;9(3):140. DOI: <https://doi.org/10.3390/jfmk9030140>
7. Concepción Obregón T, Fernández Lorenzo A, Matos Rodríguez A, Calero Morales S. Habilidades profesionales de intervención clínica según modo de actuación de estudiantes de tercer año de Estomatología. Educación Médica Superior. 2017 [acceso 15/12/2025];31(1):153-65. Disponible en: <https://ems.sld.cu/index.php/ems/article/view/941>

8. Lorenzo AF, Piedadmag DE, Oyos CR, Morales SC, Cárdenas HA. Alianzas y conflictos entre grupos de interés de un hospital militar: aplicación del método Mactor. *Revista Cubana de Investigaciones Biomédicas*. 2017 [acceso 15/12/2025];36(1):1-14. Disponible en: <https://revibiomedica.sld.cu/index.php/ibi/article/view/39>
9. Mastour H, Dehghani T, Moradi E, Eslami S. Explainable artificial intelligence for predicting medical students' performance in comprehensive assessments. *Scientific reports*. 2025;15(1):23752. DOI: <https://doi.org/10.1038/s41598-025-07460-1>
10. Meneses-La-Riva ME, Fernández-Bedoya VH, Suyo-Vega JA, Ocupa-Cabrera HG, Grijalva-Salazar RV, Ocupa-Meneses GD. Enhancing healthcare efficiency: the relationship between effective communication and teamwork among nurses in Peru. *Nursing Reports*. 2025;15(2):59. DOI: <https://doi.org/10.3390/nursrep15020059>
11. Rodríguez Torres ÁF, Páez Granja RE, Altamirano Vaca EJ, Paguay Chávez FW, Rodríguez Alvear JC, Calero Morales S. Nuevas perspectivas educativas orientadas a la promoción de la salud. *Educación Médica Superior*. 2017 [acceso 15/12/2025];31(4):1-11. Disponible en: <https://ems.sld.cu/index.php/ems/article/view/1366>
12. Vinuesa-Tapia EO, Millán-Caballero R, Sánchez-Córdova B, Calero-Morales S. Quality of management in physical activity, sports and health in the provincia de Orellana, Ecuador. *Revista Médica Electrónica*. 2025 [acceso 15/12/2025];47:e6592. Disponible en: <https://revmedicaelectronica.sld.cu/index.php/rme/article/view/6592>
13. Saunders PA, Clark L, Matthews T, Berg K, Baqai E, Ozbeki-Kimmel A, et al. Exploring empathy and patient-centered communication behaviors of third-year medical students during a clinical skills examination. *Patient education and counseling*. 2025;137:108786. DOI: <https://doi.org/10.1016/j.pec.2025.108786>
14. Kumar D, Suthar N. Predictive analytics and early intervention in healthcare social work: a scoping review. *Social work in health care*. 2024;63(4-5):208-29. DOI: <https://doi.org/10.1080/00981389.2024.2316700>
15. Mendoza KM, Burgos GD, Rivera D, Morales SC. Effects of collaborative strategies on the academic teaching-learning process of pre-youth volleyball players. *Retos: nuevas tendencias en educación física, deporte y recreación*. 2024;61:1172-83. DOI: <https://doi.org/10.47197/retos.v61.109363>

16. Torres ÁF, Munive JE, Alberca WV, Díaz MG, Ángulo JR, Morales SC. Adaptaciones curriculares en la enseñanza para alumnos con problemas respiratorios. *Revista Cubana de Medicina General Integral*. 2017 [acceso 15/12/2025];36(4):1-19. Disponible en: <http://www.revmgi.sld.cu/index.php/mgi/article/view/717/167>
17. Feigerlova E, Hani H, Hothersall-Davies E. A systematic review of the impact of artificial intelligence on educational outcomes in health professions education. *BMC Medical Education*. 2025;25(1):129. DOI: <https://doi.org/10.1186/s12909-025-06719-5>
18. Pham TD, Karunaratne N, Exintaris B, Liu D, Lay T, Yuriev E, et al. The impact of generative AI on health professional education: a systematic review in the context of student learning. *Medical Education*. 2025;29(12):1280-9. DOI: <https://doi.org/10.1111/medu.15746>
19. Lu Y, Yeom S, Maktoubian J, Rahman MM, Kim SH. Improve Student Risk Prediction with Clustering Techniques: A Systematic Review in Education Data Mining. *Education Sciences*. 2025;15(12):1695. DOI: <https://doi.org/10.3390/educsci15121695>
20. Alizadeh M, Sameri MJ. Intelligent Assessment Systems in Medical Education: A Systematic Review. *Journal of Advances in Medical Education & Professionalism*. 2025;13(3):173. DOI: <https://doi.org/10.30476/jamp.2024.104560.2068>
21. Doroszewska A, Drozdowska I, Mikołajczak M, Jasiura A, Zawadowska J. Communication Skills After Graduation: Opinions of Polish Healthcare Professionals. *Advances in Medical Education and Practice*. 2025;16:1731-40. DOI: <https://doi.org/10.2147/AMEP.S522550>
22. Hariyanto KF, Maharani R. Artificial intelligence in adaptive education: a systematic review of techniques for personalized learning. *Discover Education*. 2025;4(1):458. DOI: <https://doi.org/10.1007/s44217-025-00908-6>
23. Zheng R, Friedrich NA, Luu M, Gale R, Khodyakov D, Freedland SJ, et al. Development and validation of a natural language processing system to assess quality of physician communication in prostate cancer consultations. *Prostate cancer and prostatic diseases*. 2025;1-8. DOI: <https://doi.org/10.1038/s41391-025-01011-5>
24. Azer SA, Alhudaithi D, AlBuqami F, AlWaily H, AlRabah R, AlKhashan R. Online learning resources and social media platforms used by medical students during the

COVID-19 pandemic. BMC medical education. 2023;23(1):969. DOI: <https://doi.org/10.1186/s12909-023-04906-w>

25. Corrales-Serrano M, Nieves VA. Sports practice and social media: impact on university students' motivation to learn social sciences. Retos. 2025;73:142-56. DOI: <https://doi.org/10.47197/retos.v73.116985>

26. Dávidovics A, Dávidovics K, Hillebrand P, Rendeki S, Németh T. Virtual patient simulation to enhance medical students' clinical communication and decision-making skills: a pilot study. BMC Medical Education. 2025;26(1):171. DOI: <https://doi.org/10.1186/s12909-025-08507-7>

27. Merino-Campos C. The impact of artificial intelligence on personalized learning in higher education: A systematic review. Trends in Higher Education. 2025;4(2):17. DOI: <https://doi.org/10.3390/higheredu4020017>

28. Tbaishat D, Al-Shafei R, Odeh M. The role of AI in the diagnosis of speech and language disorders: A systematic mapping study. Digital Health. 2025;11:20552076251379769. DOI: <https://doi.org/10.1177/20552076251379769>

29. Peimani M, Tanhapour M, Majlesi M, Nasli-Esfahani E. Training in communication skills for healthcare providers in chronic care: a systematic review. BMC medical education. 2025;25(1):1314. DOI: <https://doi.org/10.1186/s12909-025-07797-1>

Conflicto de intereses

Los autores declaran que no existe conflicto de intereses.

Contribución de los autores

Conceptualización: Diana Flor García Calle.

Investigación: Mayra Lorena Becilla Vera y Diana Asunción Ortiz Salas.

Curación de Datos: Mayra Lorena Becilla Vera, Narcisa Isabel Cordero Alvarado y Karina Mariela Solano Farias.

Análisis formal: Narcisa Isabel Cordero Alvarado y Carmen Graciela Urgilés Carabajo.

Metodología: Carmen Graciela Urgilés Carabajo y Diana Asunción Ortiz Salas.

Validación: Karina Mariela Solano Farias.

Administración del proyecto: Diana Flor García Calle.

Adquisición de fondos: Aracely Jacqueline Mendoza Vega.

Redacción-borrador original: Diana Flor García Calle y Aracely Jacqueline Mendoza Vega.

Redacción-revisión y edición: Diana Flor García Calle.