

ORKO-EDU: inteligencia híbrida para el aprendizaje adaptativo y la toma de decisiones en educación médica

ORKO-EDU: Hybrid Intelligence for Adaptive Learning and Decision Making in Medical Education

Lorenzo Cevallos-Torres^{1,2*} <https://orcid.org/0000-0001-9850-0393>

Jessica Yopez-Holguin² <https://orcid.org/0009-0008-2210-3314>

Jefferson Núñez-Gaibor² <https://orcid.org/0000-0003-1319-5954>

Franklin Parrales-Bravo^{1,2} <https://orcid.org/0000-0002-6283-8197>

¹Universidad Bolivariana del Ecuador-UBE. Durán, Ecuador.

²Universidad de Guayaquil. Guayaquil, Ecuador.

*Autor para la correspondencia: ljcevallost@ube.edu.ec

RESUMEN

Introducción: ORKO-EDU es un marco de inteligencia híbrida diseñado para mejorar el aprendizaje adaptativo y la comprensión clínica de estudiantes y residentes, con especial énfasis en la nefrología.

Objetivo: Identificar un nuevo paradigma para el desarrollo de competencias clínicas en nefrología, mediante la implementación del marco ORKO-EDU.

Métodos: La metodología Descubrimiento de Conocimiento en Bases de Datos se aplicó para preprocesar y transformar datos educativos, crear perfiles de dominio y generar recomendaciones personalizadas, como selección de casos, espaciado de la práctica y retroalimentación específica, las cuales se ajustan dinámicamente según los niveles de confianza del estudiante.

Resultados: La integración de ORKO-EDU permitió una tutoría fiable, a pesar de la evidencia incompleta, lo que mejora la práctica intencional de las habilidades de diagnóstico diferencial, la modificación terapéutica y la seguridad del paciente.

Conclusiones: Las evaluaciones preliminares indican que este enfoque se correlaciona con mejoras en el desempeño en pruebas de opción múltiple y evaluaciones clínicas objetivas estructuradas, una disminución de errores durante las simulaciones y una mayor adherencia a las guías clínicas. Esto ofrece un apoyo escalable para la toma de decisiones clínicas basadas en datos y la formación.

Palabras clave: educación médica; aprendizaje adaptativo; analítica del aprendizaje; estadística neutrosófica; nefrología.

ABSTRACT

Introduction: ORKO-EDU is a hybrid intelligence framework designed to enhance adaptive learning and clinical understanding among students and residents, with a special emphasis on nephrology.

Objective: To identify a new paradigm for developing clinical competencies in nephrology through the implementation of the ORKO-EDU framework.

Methods: The Knowledge Discovery in Databases methodology was applied to preprocess and transform educational data, create domain profiles, and generate personalized recommendations –such as case selection, practice spacing, and specific feedback– which dynamically adjust according to student confidence levels.

Results: The integration of ORKO-EDU enabled reliable tutoring, despite incomplete evidence, enhancing the intentional practice of differential diagnosis skills, therapeutic modification, and patient safety.

Conclusions: Preliminary assessments indicate that this approach correlates with improvements in multiple-choice test performance and objective structured clinical evaluations, a reduction in errors during simulations, and increased adherence to clinical guidelines. This provides scalable support for data-driven clinical decision-making and training.

Keywords: medical education; adaptive learning; learning analytics; neutrosophic statistics; nephrology.

Recibido: 09/12/2025

Aceptado: 10/12/2025

Introducción

La enfermedad renal crónica (ERC) es un problema de salud global creciente que requiere monitorización continua, atención personalizada y la participación activa del paciente. Sin embargo, la escasa alfabetización en salud y la incertidumbre inherente a los datos clínicos suelen dificultar el manejo eficaz de la enfermedad y el autocuidado. La complejidad de la ERC exige soluciones innovadoras, capaces de procesar datos diversos de los pacientes y ofrecer intervenciones personalizadas.⁽¹⁾

En este contexto, SCOPE (optimización del autocuidado y empoderamiento del paciente) surge como un marco híbrido sólido que integra la inteligencia artificial (IA) con la estadística neutrosófica. Al abordar tanto la incertidumbre de los datos como la participación del paciente, SCOPE mejora la toma de decisiones, la interpretabilidad y las recomendaciones personalizadas. Su objetivo es empoderar a las personas con una mayor comprensión de su salud, al tiempo que apoya a los sistemas sanitarios en la prestación de una atención adaptativa y centrada en el paciente.⁽²⁾

Por otro lado, el uso de la inteligencia artificial híbrida, diseñada para mejorar el aprendizaje adaptativo y la comprensión clínica de estudiantes y residentes, con especial énfasis en la nefrología, se convierte en un desafío de alcance global.⁽³⁾ Esto se logra mediante la integración de redes neuronales de memoria a largo plazo (LSTM) y estadística neutrosófica, que abordan el doble desafío de extraer patrones significativos de las series temporales de su desempeño y actividad formativa, mientras resuelven la incertidumbre evaluativa asociada a su práctica pedagógica.⁽⁴⁾

De igual manera, al aplicar la metodología de descubrimiento de conocimiento en bases de datos (KDD), se preprocesan estos datos heterogéneos para crear perfiles docentes precisos y generar recomendaciones personalizadas de capacitación, tales como la selección de casos clínicos, el espaciado de la práctica y la retroalimentación específica, ajustadas dinámicamente a su nivel de competencia. Los resultados preliminares de este enfoque indican una mejora en su desempeño evaluativo, una disminución de errores en simulaciones de enseñanza y una mayor

adherencia a las mejores prácticas educativas, lo que ofrece un apoyo escalable para el desarrollo docente basado en datos.⁽⁵⁾

Para implementar eficazmente este enfoque basado en competencias dentro de un sistema específico, el componente de estadística neutrosófica del marco ORKO-EDU (optimización del conocimiento renal para la educación médica) es esencial. La capacidad de cuantificar y gestionar la incertidumbre en la evaluación del desempeño complejo permite transformar los principios teóricos en procesos técnicos que sean prácticos.⁽⁶⁾ Este componente establece una base sólida para el sistema, mediante el modelado matemático de imprecisiones, contradicciones e información incompleta en los datos educativos, lo que permite la creación de perfiles docentes fiables y la formulación de recomendaciones significativas.⁽⁷⁾

El marco ORKO-EDU requiere un enfoque basado en competencias para garantizar un desempeño eficaz, creativo y crítico en la docencia, la investigación y los servicios profesionales. Un desafío importante radica en la frecuente insuficiencia de la preparación pedagógica del profesorado, lo que dificulta la formación de profesionales con un perfil innovador y pedagógicamente sólido.^(8,9) Sin embargo, el sistema propuesto aborda este problema mediante el desarrollo de perfiles docentes basados en competencias y la provisión de recomendaciones de desarrollo profesional personalizadas, fundamentadas en el procesamiento inteligente de datos educativos.^(10,11)

En el marco ORKO-EDU, la estadística neutrosófica cumple una función crítica, al ofrecer un sustento formal para cuantificar e interpretar la incertidumbre evaluativa presente en los datos de seguimiento de docentes y estudiantes de nefrología. Esta capacidad permite, a su vez, generar recomendaciones de formación y retroalimentación más adaptables, contextualmente sensibles y personalizadas. En consecuencia, el componente neutrosófico no solo incrementa la solvencia interpretativa del modelo, sino que potencia y complementa de manera sinérgica los algoritmos de inteligencia artificial, como las redes LSTM, lo que mejora la resiliencia global del sistema ante la ambigüedad e indeterminación de los entornos educativos reales.⁽¹⁴⁾

Finalmente, la integración de la estadística neutrosófica, las redes LSTM y la metodología KDD en el marco de ORKO-EDU representan un avance significativo en la formación médica especializada. Este enfoque híbrido proporciona un sistema robusto, que transforma datos educativos heterogéneos e inciertos en perfiles de competencias precisos y recomendaciones personalizadas. Aborda desafíos metodológicos específicos, como la gestión de la incertidumbre evaluativa y la extracción de patrones temporales, al tiempo que establece un nuevo paradigma para el desarrollo de competencias clínicas. ORKO-EDU se consolida como una

plataforma escalable y basada en la evidencia, que mejora el aprendizaje adaptativo, optimiza la toma de decisiones educativas y, en última instancia, eleva la calidad de la formación de los profesionales sanitarios.⁽¹⁵⁾

El objetivo de este estudio fue identificar un nuevo paradigma para el desarrollo de competencias clínicas en nefrología, mediante la implementación del marco ORKO-EDU.

Métodos

El modelo empleó una base de datos educativa especializada y la metodología KDD, mediante técnicas de Aprendizaje Automático, particularmente redes LSTM, para identificar patrones temporales en datos secuenciales de desempeño clínico. Esta integración facilitó la identificación de tendencias de aprendizaje, predijo necesidades de capacitación específicas y generó itinerarios de formación personalizados, lo cual ha establecido a ORKO-EDU como una plataforma escalable y basada en evidencia, que mejora el aprendizaje adaptativo, optimiza la toma de decisiones educativas y eleva la calidad de la formación para los profesionales de la salud.⁽¹⁶⁾

Selección y definición del problema

La educación superior en ciencias de la salud debe transitar de los métodos de enseñanza convencionales, principalmente estandarizados y centrados en la transmisión unidireccional de conocimientos, a estrategias que enfaticen en el desarrollo de sólidas competencias clínicas y el aprendizaje adaptativo. Este paradigma requiere una evaluación detallada y continua del desempeño de estudiantes y residentes, lo que genera una gran cantidad de datos diversos, incluyendo el desempeño en simulaciones ECOE, los resultados de cuestionarios, las interacciones en entornos virtuales y las secuencias de casos clínicos resueltos. La complejidad de estos datos, marcada por su naturaleza temporal, su frecuente carácter incompleto y las rúbricas de evaluación subjetivas, impide a las instituciones obtener información práctica necesaria para una formación personalizada y una retroalimentación oportuna y significativa.⁽¹⁷⁾

Este estudio se centra en el reto de integrar de forma eficiente y automática el análisis de datos educativos complejos y secuenciales con la gestión de la incertidumbre evaluativa presente en el proceso de formación clínica. Esto

dificulta el desarrollo de sistemas de aprendizaje adaptativo eficaces. Existe una brecha metodológica entre la recopilación de datos sobre el rendimiento del alumnado y la generación de recomendaciones pedagógicas personalizadas y fiables. Esta brecha se evidencia en las limitaciones de los sistemas convencionales para:

- a) extraer patrones significativos de series temporales de aprendizaje que reflejen el desarrollo de competencias;
- b) cuantificar y abordar la imprecisión, las contradicciones y la falta de datos en las evaluaciones; y
- c) convertir este análisis exhaustivo en intervenciones educativas dinámicas, basadas en la evidencia, y adaptadas a los niveles de competencia y confianza de cada futuro profesional sanitario.⁽¹⁸⁾

La estrategia formulada para abordar este problema implica el desarrollo y la implementación del marco ORKO-EDU, que aboga por una integración metodológica híbrida. Esta integración combina eficazmente tres componentes fundamentales:

- 1. La metodología de KDD: sirve como marco para el preprocesamiento, la transformación y la extracción de datos educativos.
- 2. Las LSTM: expertas en el reconocimiento de patrones complejos y dependencias a largo plazo en series temporales de aprendizaje.
- 3. La estadística neutrosófica: ofrece un marco matemático para abordar cuantitativamente la incertidumbre, la imprecisión y la información incompleta en los datos y las rúbricas de evaluación.^(19,20)

La integración de estas tecnologías facilita el desarrollo de perfiles de competencias dinámicos y la provisión de recomendaciones de aprendizaje personalizadas, incluyendo la selección adaptativa de casos clínicos, la optimización del espaciado de la práctica y la retroalimentación específica. Este proceso culmina en un sistema inteligente que mejora el desarrollo de competencias clínicas.

Presupuestos de partida

Los presupuestos de partida que guiaron el proceso de la metodología de KDD proporcionan un marco estructurado para extraer patrones significativos de datos sanitarios complejos. En el contexto del modelo ORKO-EDU, KDD permite la integración de la inteligencia artificial y la estadística neutrosófica para fomentar la alfabetización en salud y el autocuidado en pacientes con enfermedad renal crónica. Este enfoque implica seleccionar datos clínicos y conductuales relevantes, limpiarlos y transformarlos, aplicar técnicas de aprendizaje automático e interpretar los resultados para generar recomendaciones personalizadas.

Por otro lado, el uso de redes LSTM mejora el reconocimiento de patrones en datos secuenciales, mientras que la lógica neutrosófica aborda la incertidumbre y la variabilidad. En conjunto, estas herramientas crean un sistema robusto de apoyo a la decisión.

La metodología de KDD está estrechamente relacionada con el modelo ORKO-EDU en educación médica, ya que ambos buscan extraer conocimiento valioso de datos complejos, si bien en contextos distintos: KDD opera dentro de bases de datos, mientras que ORKO-EDU se utiliza en entornos de aprendizaje clínico caracterizados por la incertidumbre.

A continuación se describe la alineación de cada fase de KDD con los objetivos educativos de ORKO-EDU:

- Fase de selección de datos: se identifican las variables educativas relevantes, tales como desempeño en ECOE, resultados de MCQ, registros de interacción y tiempos de respuesta en simulaciones. El conjunto de datos utilizado para el modelo ORKO-EDU consta de 1200 registros, que abarcan una amplia gama de datos clínicos, nutricionales y conductuales relacionados con pacientes con enfermedad renal crónica. Las variables incluyen atributos demográficos (por ejemplo, edad y sexo), datos antropométricos (peso, talla, IMC), marcadores clínicos (creatinina, glucosa plasmática total, proteinuria), ingesta dietética (sodio, potasio, proteínas) y factores del estilo de vida (actividad física, retención de líquidos). La variable Resultados Salud sirve como medida de resultado para el estado de salud. En la educación médica esta etapa define qué indicadores de aprendizaje clínico son significativos para modelar la progresión del estudiante, por ejemplo: seleccionar variables que reflejen razonamiento diagnóstico o adherencia a protocolos terapéuticos (tabla 1).

Tabla 1 - Operacionalización de variables y rangos de clasificación

Variable	Alta (T)	Media (I)	Baja (F)
Ingesta de sodio	2500-3500 mg	1500-2500 mg	0-1500 mg
Ingesta de potasio	3000-4000 mg	2000-3000 mg	0-2000 mg
Peso corporal	80-100 kg	60-80 kg	40-60 kg
Hidratación	Alta	Media	Baja
Puntaje de dieta saludable	8-10 (óptima)	5-7 (moderada)	1-4 (no saludable)
Presión arterial sistólica	> 140 mmHg	120-139 mmHg	< 120 mmHg
Nivel de creatinina	> 1,5 mg/dl	1,0-1,5 mg/dl	< 1,0 mg/dl
Tasa de filtración glomerular	> 90 ml/min	60-89 ml/min	< 60 ml/min
Nivel de proteína en orina	> 30 mg/dl	15-30 mg/dl	< 15 mg/dl

- Fase de preprocesamiento de datos: se centra en preparar el conjunto de datos para un análisis preciso y eficiente, lo que garantiza su calidad y consistencia. En este paso, los valores faltantes (NA) se eliminan o se imputan mediante técnicas estadísticas apropiadas para preservar la integridad de los datos. Las variables categóricas, como la actividad física, la masa muscular y la dieta proteica, se convierten a formatos numéricos para permitir la compatibilidad con el modelo de aprendizaje automático. Las variables clínicas clave, como la creatinina, la glucosa plasmática total (GPT) y el consumo de sodio, se normalizan o estandarizan para asegurar una escala uniforme y prevenir sesgos en el modelo. Esto permite crear una base de datos educativa confiable, incluso cuando la evidencia no es completa o resulta contradictoria. Estas tareas de preprocesamiento se convierten en esenciales para reducir el ruido y mejorar el rendimiento general del modelo predictivo ORKO-EDU.
- Fase de transformación de datos: se centra en mejorar el conjunto de datos, mediante la creación de nuevos atributos o el perfeccionamiento de los existentes para optimizar el rendimiento analítico. Dentro del marco del modelo ORKO-EDU, los datos educativos se transforman en índices de riesgo o dominio, al codificar el progreso del estudiante y sus áreas críticas; por ejemplo: generar un índice de confianza diagnóstica o un perfil de competencias clínicas. Estos valores permiten que el sistema reconozca patrones de aprendizaje y priorice retroalimentaciones específicas.

Evidencia de integración analítica y pedagógica

El diagrama de caja sirve como una herramienta visual eficaz para transmitir análisis estadísticos en contextos educativos. Desde el punto de vista de la KDD, el gráfico valida la relevancia de las nuevas variables transformadas; y, desde el aprendizaje adaptativo, visualiza patrones clínicos que facilitan la comprensión conceptual y la toma de decisiones (fig. 1).

En términos neutrosóficos, la variabilidad entre grupos de edad puede asociarse a diferentes grados de indeterminación o incertidumbre clínica, lo que refuerza la necesidad de usar modelos híbridos (IA + lógica neutrosófica).

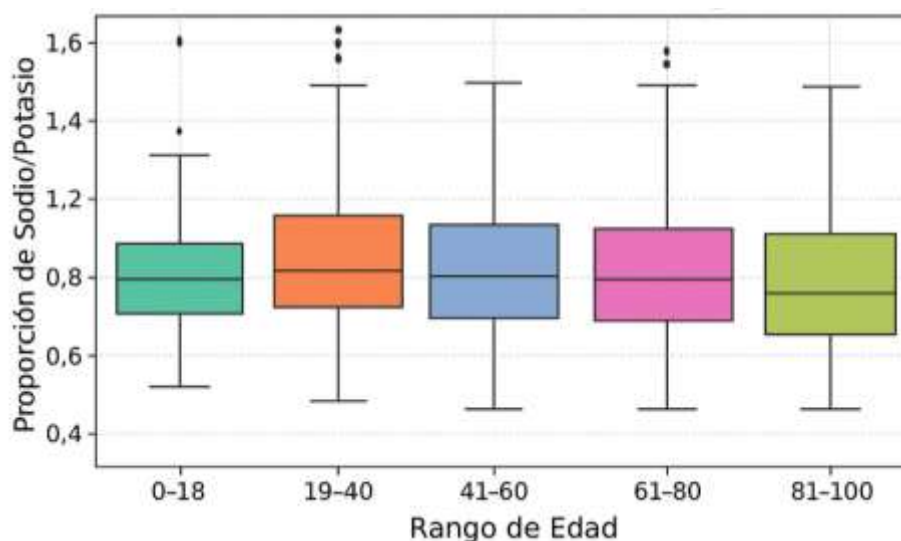


Fig. 1 - Diagramas de cajas para relación sodio/potasio por grupo de edad.

Vinculación con los objetivos educativos del modelo ORKO-EDU

El modelo ORKO-EDU tiene como objetivo analizar datos clínicos y capacitar a estudiantes de medicina en el razonamiento basado en datos. En consecuencia, transforma los datos brutos en un concepto clínicamente aplicable con fines educativos, como elucidar el impacto del cociente Na/K en la función renal. Asimismo, mejora las habilidades de análisis interpretativo de los futuros médicos y les enseña a reconocer indicadores esenciales dentro de las complejidades de los registros clínicos. También facilita la capacidad del sistema para generar retroalimentación adaptativa, al ilustrar los efectos de las modificaciones nutricionales en la progresión renal o el análisis de los resultados de las pruebas.

Minería de datos

Para extraer patrones y predicciones relevantes del conjunto de datos transformado, la fase de minería de datos emplea técnicas analíticas avanzadas. Con el fin de pronosticar valores futuros de indicadores clínicos significativos, las redes LSTM son fundamentales para el marco ORKO-EDU, que analiza series temporales de aprendizaje, incluyendo la progresión de casos clínicos, la evolución de los errores y el rendimiento longitudinal de los estudiantes. Este análisis permite al sistema comprender la evolución de la comprensión clínica individual y facilita modificaciones dinámicas a las recomendaciones personalizadas, como la distribución de la práctica y la secuenciación de casos. Además, se pueden identificar con precisión patrones de mejora o estancamiento en el razonamiento clínico, para optimizar el proceso de aprendizaje basado en datos.

Elección de la unidad de análisis

La unidad de análisis es el estudiante de medicina o residente que participa en el entorno de formación ORKO-EDU, centrado en su trayectoria de aprendizaje clínico, según lo indican las variables observables en las bases de datos. Cada estudiante constituye una unidad de análisis, que comprende una serie temporal que incluye:

- Resultados de la evaluación teórica (preguntas de opción múltiple)
- Evaluación del desempeño en exámenes clínicos objetivos estructurados (ECOE)
- Indicadores de la práctica simulada, que incluyen el razonamiento diagnóstico y las decisiones terapéuticas
- Variables clínicas vinculadas a casos reales o simulados, que incluyen la presión arterial, la relación sodio/potasio, los niveles de creatinina y la tasa de filtración glomerular
- Niveles de confianza e incertidumbre en la toma de decisiones con respecto a los componentes de los neutrófilos

Justificación

La selección del estudiante como unidad de análisis se alinea con los objetivos del modelo ORKO-EDU, por las siguientes razones:

- Facilita la integración del proceso educativo con el desarrollo de competencias clínicas
- Permite el modelado temporal del aprendizaje mediante redes LSTM para series longitudinales por estudiante
- Integra la observación con una metodología personalizada y adaptativa, lo que asegura que las decisiones educativas se ajusten al perfil de cada estudiante
- Abarca dimensiones cognitivas y procedimentales (desempeño clínico), junto con elementos afectivos e inciertos (niveles de indeterminación o confianza)

Resultados

Fase descriptiva

El comportamiento de aprendizaje clínico se caracteriza por los resultados obtenidos en esta etapa. La práctica médica de los estudiantes se analiza describiendo datos relevantes e identificando patrones generales. Las variables relevantes incluyen el desempeño en la ECOE, los resultados de las preguntas de opción múltiple, la relación sodio/potasio y la adherencia al tratamiento. Los diagramas de caja por grupo de edad o nivel de competencia son solo un ejemplo de cómo el análisis estadístico básico y las visualizaciones pueden ayudar a comprender la distribución del conocimiento de los participantes y sus diferencias iniciales (fig. 2).

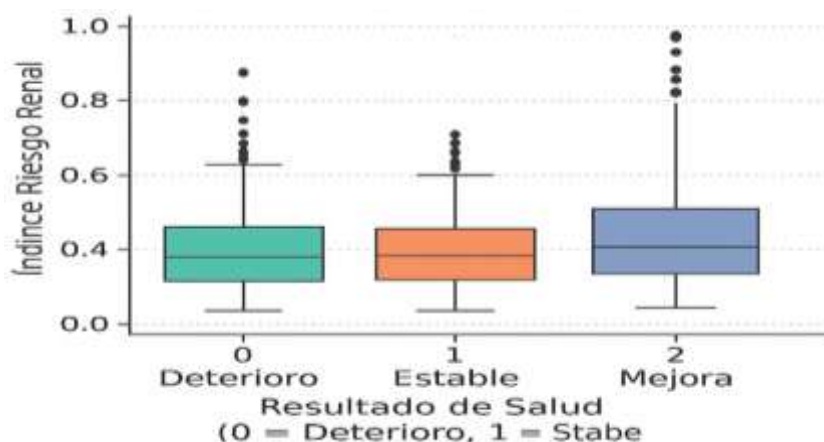


Fig. 2 - Diagrama de cajas y bigotes Índice riesgo Renal

Fase interpretativa

El objetivo de este paso es encontrar significado en los patrones identificados. Las incertidumbres en las evaluaciones médicas, como las rúbricas, los diagnósticos poco claros y la falta de datos, se pueden comprender mediante la inclusión de la estadística neutrosófica. En este punto, el sistema ORKO-EDU comienza a contextualizar el aprendizaje: por ejemplo, asocia una puntuación baja en un caso clínico con problemas en el razonamiento diagnóstico o la interpretación de los signos renales. La elaboración de explicaciones comprensibles facilita la toma de decisiones clínicas y formativas.

En el contexto del modelo educativo ORKO-EDU, el enfoque híbrido que combina redes LSTM con estadística neutrosófica, alcanzó una precisión del 92 %, por lo que superó tanto al LSTM puro (87 %) como al exclusivamente neutrosófico (78 %). Esta mejora refleja la capacidad del sistema para analizar de forma robusta las trayectorias de aprendizaje clínico, al manejar simultáneamente la variabilidad temporal del desempeño y la incertidumbre evaluativa propia de las rúbricas médicas. La matriz de confusión muestra este rendimiento, con 85 verdaderos positivos y 97 verdaderos negativos. Esto indica que el modelo identifica con gran precisión a los estudiantes que necesitan ayuda en habilidades clínicas y a los que tienen un buen desempeño.

La precisión del 91,4 % en predicciones positivas confirma su fiabilidad, al señalar áreas de riesgo pedagógico, mientras que su especificidad del 92,4 % demuestra su capacidad para evitar falsas alarmas en estudiantes con desempeño satisfactorio. Además, su sensibilidad del 89,5 % destaca su efectividad para identificar casos reales de problemas académicos o errores clínicos importantes durante

simulaciones y ECOE. Estos resultados validan la pertinencia del enfoque híbrido dentro del ciclo KDD, lo que lo consolida como una herramienta pedagógica idónea para generar recomendaciones adaptativas, fortalecer el razonamiento clínico y apoyar la toma de decisiones educativas basadas en datos reales e inciertos.

Fase de yuxtaposición

En esta etapa se presentan los hallazgos que intentaron vincular las diversas dimensiones del aprendizaje. Se realiza una comparación de características clínicas y educativas, como la creatinina y la tasa de filtración glomerular, así como del desempeño longitudinal y los comentarios recibidos. Este análisis muestra que la comprensión práctica y el conocimiento médico del estudiante se desarrollan simultáneamente, o al menos de forma paralela. Al contrastar ambos aspectos, se pueden crear con mayor facilidad intervenciones educativas integradas basadas en correlaciones reales.

Con estos datos sincronizados, se pueden identificar similitudes y diferencias en la comprensión teórica del estudiante, su desempeño clínico y la trayectoria temporal de los modelos LSTM para su evolución. Al comparar ambos aspectos, puede observarse si la mejora en la toma de decisiones clínicas del estudiante –basada en factores como el equilibrio sodio/potasio derivado de la fase de transformación– se acompaña de una mejora cognitiva cuantificable, o si un estudiante con un sólido conocimiento de biomarcadores aún comete errores.

Fase comparativa

Al comparar los resultados, se puede evaluar cómo difieren entre sí los distintos grupos o etapas de formación. Los estudiantes de primer año y los residentes son dos ejemplos de cohortes con las que ORKO-EDU puede comparar el rendimiento. También puede comparar el rendimiento antes y después de una intervención didáctica, como una sesión de simulación o retroalimentación adaptativa. En entornos clínicos, la eficacia de la instrucción individualizada y la mitigación de errores diagnósticos y terapéuticos se evalúan comparando las respuestas a diversos casos clínicos de nefrología.

Los resultados de la fase comparativa revelan que, al evaluar el desempeño del análisis clínico-educativo, el modelo híbrido (LSTM + estadística neutrosófica) supera sistemáticamente a los modelos individuales. Con una precisión del 91,4 %, el método integrado demostró que la mayoría de las predicciones sobre los que necesitaban intervención eran correctas. Su especificidad del 92,4 % verifica su

fiabilidad para identificar con precisión a los alumnos cuyo rendimiento es suficiente y que no requieren refuerzo; y su sensibilidad del 89,5 % demuestra una sólida capacidad para detectar casos reales de dificultades académicas o errores clínicos relevantes.

Debido a que tanto la información faltante como las falsas alarmas pueden comprometer la formación clínica y la seguridad del paciente, lograr este equilibrio es de suma importancia en la educación médica. Al verificar que existen beneficios sustanciales al combinar el análisis temporal del aprendizaje con la gestión de la incertidumbre evaluativa, el modelo híbrido logra mejores resultados que el modelo LSTM solo (precisión: 87 %, sensibilidad: 88 %, especificidad: 85 %) o el modelo puramente neutrosófico (precisión: 78 %, sensibilidad: 75 %, especificidad: 80 %) (tabla 2).

Tabla 2 - Métricas derivadas y comparación de modelos

Métrica	LSTM	Neutrosófico	Híbrido
Precisión	87 %	78 %	92 %
Sensibilidad	88 %	75 %	89,50 %
Especificidad	85 %	80 %	92,40 %

Fase prospectiva

Por último, los hallazgos prospectivos demuestran la capacidad predictiva y de orientación del modelo. Mediante el uso de redes LSTM, ORKO-EDU puede prever posibles áreas problemáticas o áreas de mejora para los estudiantes, proyectando su desempeño clínico a lo largo del tiempo. Ajustar el orden de los casos clínicos, destacar habilidades específicas o sugerir materiales de estudio según el perfil de aprendizaje son ejemplos de cómo estas predicciones se traducen en recomendaciones didácticas individualizadas. Además, permite modelar situaciones prácticas y pronosticar los posibles efectos de los cambios de comportamiento o las decisiones clínicas en la seguridad del paciente en el ámbito médico.

Discusión

Estudios recientes por *Kulasegaram* y otros⁽²¹⁾ han demostrado que la integración de inteligencia artificial avanzada en la formación médica permite transformar datos clínicos y educativos en conocimiento significativo para mejorar el aprendizaje. Por ejemplo, la literatura muestra que el uso de modelos basados en aprendizaje profundo y análisis de series temporales facilita la identificación de patrones de desempeño clínico, lo que permite generar retroalimentación personalizada y detectar trayectorias de mejora en los estudiantes. Además, enfoques híbridos que combinan análisis algorítmico con técnicas de manejo de incertidumbre han sido aplicados para fortalecer la evaluación clínica y abordar problemas comunes de datos incompletos o ambiguos en entornos educativos. Estas investigaciones respaldan la idea de que los marcos híbridos, similares al planteado con ORKO-EDU y KDD, pueden optimizar la formación clínica mediante sistemas adaptativos que modelan el aprendizaje como un proceso evolutivo y contextual.

Por su parte, Martínez & Fernández ⁽²²⁾ han destacado que los hallazgos preliminares refuerzan su tesis al demostrar que los sistemas adaptativos no solo optimizan la trayectoria de aprendizaje, sino que fomentan la agencia del estudiante mediante mecanismos de autorreflexión guiada. Sin embargo, se advierten riesgos de sobrecarga cognitiva si la personalización no contiene criterios pedagógicos claros. En línea con estos hallazgos, una investigación complementaria podría explorar la transferibilidad de los modelos matemáticos adaptativos identificados, aplicándolos en contextos de educación superior en ciencias de la salud o ingeniería, donde los conceptos abstractos también son predominantes.

Según *Smarandache*,⁽⁶⁾ la lógica y la estadística neutrosóficas son herramientas esenciales para gestionar la incertidumbre inherente a los sistemas de educación médica, sobre todo al trabajar con datos incompletos, imprecisos o contextualmente heterogéneos. Este enfoque proporciona una representación más precisa del conocimiento pedagógico-clínico en escenarios donde la evaluación de la docencia y el desempeño estudiantil no puede basarse en criterios absolutos.^(12,13)

ORKO-EDU representa un avance hacia una educación médica basada en la evidencia, predictiva, adaptativa, y que analiza constantemente datos reales y simulados para construir conocimiento.

Para *Chen* y otros,⁽²³⁾ la metodología KDD optimiza la conversión de datos clínicos y educativos en información valiosa para la educación médica. Las redes LSTM se

distinguen por su habilidad para representar la evolución temporal del rendimiento académico e identificar patrones de mejora o estancamiento. Además, estrategias de gestión de incertidumbre, tales como la lógica difusa y la neutrosofía, potencian la fiabilidad de las evaluaciones clínicas. La incorporación de estos métodos facilita la creación de retroalimentaciones personalizadas y la elaboración de intervenciones pedagógicas más exactas. En su totalidad, estos descubrimientos corroboran la capacidad de los sistemas inteligentes para optimizar la educación médica fundamentada en datos.

Finalmente, ORKO-EDU promueve una formación médica más reflexiva y precisa, donde los estudiantes aprenden a interpretar sus propios datos de desempeño y a tomar decisiones clínicas basadas en la evidencia, lo que mejora su razonamiento diagnóstico y su adherencia a las guías clínicas. El modelo sienta las bases para el desarrollo de un ecosistema inteligente de educación médica, capaz de integrar IA, análisis de aprendizaje automático y modelos predictivos para mejorar la seguridad del paciente y la competencia profesional de los futuros médicos.

Referencias bibliográficas

1. Graham-Brown MPM, Smith AC, Greenwood SA. Digital health interventions in chronic kidney disease: levelling the playing field? Clin Kidney J. 2023;16(5):763-7. DOI: <https://doi.org/10.1093/ckj/sfac259>
2. Erturkmen GBL, Juul NK, Redondo IE, Ortega Gil A, Verdoy Berastegui D, De Manuel E, *et al.* Design, implementation and usability analysis of patient empowerment in ADLIFE project via patient reported outcome measures and shared decision making. BMC Med Inform Decis Mak. 2024;24:185. DOI: <https://doi.org/10.1186/s12911-024-02588-y>
3. Miao J, Thongprayoon C, Craici IM, Cheungpasitporn W. How to incorporate generative artificial intelligence in nephrology fellowship education. J Nephrol. 2024;37:2491-7. DOI: <https://doi.org/10.1007/s40620-024-02165-6>
4. Saravanaraj SS, Govindan V, Donganont M, Said B. Integrating Neutrosophic Logic with Bi-directional LSTM Model for Predicting Stock Market Movements. Int. J. Neutrosophic Sci. 2025;25(2):84-92. DOI: <https://doi.org/10.54216/IJNS.250208>
5. Cevallos-Torres L, Botto-Tobar M. Case study: Project-based learning to evaluate probability distributions in medical area. Rev. Dialogus. 2019;(6):111-22. DOI: https://doi.org/10.1007/978-3-030-13393-1_7

6. Smarandache F. La Estadística Neutrosófica es una extensión de la Estadística de Intervalos, mientras que la Estadística Plitogénica es la forma más general de estadística. *Neutrosophic Comput. Mach. Learn.* 2022;23:21-38. DOI: <https://doi.org/10.5281/zenodo.7328549>
7. Macazana Fernández DM, Ramos Palacios WF, Pinto Pagaza DA, Mendoza Hidalgo ML, Espinoza Moreno TM. Impacto de las estadísticas neutrosóficas en el proceso de enseñanza-aprendizaje. *Neutrosophic Comput Mach Learn.* 2024;35:220-30. DOI: <https://doi.org/10.5281/zenodo.14271092>
8. Guerrero-Bermúdez ÁE, Vivar-Sigcho MV, Campo-Saransig DA, Reyes-Guzmán A. El papel del docente en la construcción del pensamiento crítico en la educación superior. *Space Sci J Multidiscip.* 2023;1(3):30-43. DOI: <https://doi.org/10.63618/omd/ssjm/v1/n3/18>
9. Veintimilla Castillo CE, Zambrano Arias CG, Guilarte Legrá M, García Hevia S. La formación pedagógica continua y su contribución al desempeño profesional de los docentes. *Cienc Educ.* 2025;6(4):114-26. DOI: <https://doi.org/10.5281/zenodo.15277272>
10. Castro G, Cárdenas-Cobo J, Tenutto-Soldevilla M, Vidal-Silva C. Analyzing the teaching profile and competency-based training in online education: a case study of Ecuadorian professors. *Front. Educ.* 2024;9:1397086. DOI: <https://doi.org/10.3389/feduc.2024.1397086>
11. Leibur T, Saks K. Leveraging learning analytics to support teachers' professional development: insights from a digital application. *Front. Educ.* 2025;10:1639217. DOI: <https://doi.org/10.3389/feduc.2025.1639217>
12. Kumar P, Moazzamigodarzi M, Rahimi M. Neutrosophic analysis of experimental data using neutrosophic Graeco-Latin square design. *Axioms.* 2024;13(8):559. DOI: <https://doi.org/10.3390/axioms13080559>
13. Parra Castellanos MRP, Iznaga Brooks HL, Díaz Chieng LY, Hodelín-Hodelín Y. Análisis estadístico neutrosófico sobre la caracterización de la Universidad Virtual de Salud durante la COVID-19, Universidad de Ciencias Médicas Guantánamo. *Neutrosophic Computing and Machine Learning.* 2023;27:137-46. DOI: <https://doi.org/10.5281/zenodo.8241964>
14. Lin YL, Chiang YM, Tsai TC, Su SG. Knowledge-point classification using simple LSTM-based and siamese-based networks for virtual patient simulation. *BMC Med Inform Decis Mak.* 2025;25(1):39. DOI: <https://doi.org/10.1186/s12911-025-02866-3>

15. Yang L, Zheng S, Xu X, Sun Y, Wang X, Li J. Medical Data Mining Course Development in Postgraduate Medical Education: Web-Based Survey and Case Study. *JMIR Med Educ.* 2021;7(4):e24027. DOI: <https://doi.org/10.2196/24027>
16. Khoshgoftar Z, Babaei M, Rouzbahani AK, Kalantarion M. Educational data mining in medical education: A five-level approach. *J Educ Health Promot.* 2025;14:24. DOI: https://doi.org/10.4103/jehp.jehp_1339_23
17. Chen F, Cui Y. Utilizing student time series behaviour in learning management systems for early prediction of course performance. *J Learn Anal.* 2020;7(2):1-17. DOI: <https://doi.org/10.18608/jla.2020.72.1>
18. Bojic I, Mammadova M, Ang CS, Teo WL, Diordieva C, Pienkowska A, *et al.* Empowering health care education through learning analytics: In-depth scoping review. *J Med Internet Res.* 2023;25:e41671. DOI: <https://doi.org/10.2196/41671>
19. Fazil M, Rísquez A, Halpin C. A Novel Deep Learning Model for Student Performance Prediction Using Engagement Data. *J Learn Anal.* 2024;11(2):23-41. DOI: <https://doi.org/10.18608/jla.2024.7985>
20. Aslam M. Uncertainty-driven generation of neutrosophic random variates from the Weibull distribution. *J Big Data.* 2023;10:177. DOI: <https://doi.org/10.1186/s40537-023-00860-y>
21. Kulasegaram K, Rangwala F, Moineau G, Norman G. *Artificial intelligence in medical education: A systematic review exploring its impact on assessment and learning.* *Medical Education.* 2023;57(4):345-59. DOI: <https://doi.org/10.1111/medu.14957>
22. Martínez, J. A., & Fernández, L. (2023). El rol del aprendizaje adaptativo en la educación híbrida: Tecnologías emergentes para potenciar la autonomía del estudiante. *Revista de Innovación Educativa*, 12(4), 89-112. DOI: <https://doi.org/10.61368/r.s.d.h.v6i1.532>.
23. Chen X, Zou D, Xie H, Cheng G, Liu C. *Two decades of artificial intelligence in education: A bibliometric analysis.* *Journal of Educational Computing Research*, 2020;58(8):1464-92. DOI: <https://doi.org/10.1177/0735633120952064>

Conflicto de intereses

Los autores declaran que no existe conflicto de intereses.

Contribución de los autores

Conceptualización: Lorenzo Cevallos-Torres, Jessica Yépez-Holguín, Jefferson Núñez-Gaibor y Franklin Parrales-Bravo.

Curación de datos: Lorenzo Cevallos-Torres y Franklin Parrales-Bravo.

Análisis formal: Jessica Yépez-Holguín.

Adquisición de fondos: Jefferson Núñez-Gaibor.

Investigación: Lorenzo Cevallos-Torres, Jessica Yépez-Holguín, Jefferson Núñez-Gaibor y Franklin Parrales-Bravo.

Metodología: Lorenzo Cevallos-Torres y Jessica Yépez-Holguín.

Administración del proyecto: Lorenzo Cevallos-Torres.

Recursos: Jessica Yépez-Holguín.

Software: Jefferson Núñez-Gaibor.

Supervisión: Lorenzo Cevallos-Torres.

Validación: Lorenzo Cevallos-Torres.

Visualización: Franklin Parrales-Bravo.

Redacción-borrador original: Lorenzo Cevallos-Torres, Jessica Yépez-Holguín, Jefferson Núñez-Gaibor y Franklin Parrales-Bravo.

Redacción-revisión y edición: Lorenzo Cevallos-Torres, Jessica Yépez-Holguín, Jefferson Núñez-Gaibor y Franklin Parrales-Bravo.