

**PERCEPCIÓN DEL PERSONAL MÉDICO SOBRE EL USO DE INTELIGENCIA
ARTIFICIAL EN LA TOMA DE DECISIONES CLÍNICAS EN ONCOLOGÍA
HEALTHCARE PROFESSIONALS' PERCEPTIONS OF THE USE OF ARTIFICIAL
INTELLIGENCE IN CLINICAL DECISION-MAKING IN ONCOLOGY**

Autores: ¹Fanny Michelle Meléndez Yáñez, ²Luis Fabián Salazar Garcés.

¹ORCID ID: <https://orcid.org/0009-0009-9348-4043>

²ORCID ID: <https://orcid.org/0000-0002-5128-7211>

¹E-mail de contacto: fmelendez1157@uta.edu.ec

²E-mail de contacto: lf.salazar@uta.edu.ec

Afiliación: ¹*Facultad de Ciencias de la Salud, Universidad Técnica de Ambato, (Ecuador). ²*Allergy and Acarology Laboratory, Institute of Health Sciences, Federal University of Bahia.

Artículo recibido: 30 de Julio del 2026.

Artículo revisado: 1 de Agosto del 2026.

Artículo aprobado: 1 de Agosto del 2026.

¹Estudiante de la Universidad Técnica de Ambato, (Ecuador).

²Licenciado en Laboratorio Clínico, graduado de la Universidad Técnica de Ambato, (Ecuador). Magíster en Inmunología, graduado de la Universidad Federal Da Bahia, (Brasil). Doctor en Inmunología, graduada de la Universidad Federal Da Bahia, (Brasil).

Resumen

El objetivo es analizar la percepción del personal médico del Hospital de Especialidades Carlos Andrade Marín (HECAM) sobre el uso de inteligencia artificial (IA) en el manejo del cáncer de mama, explorando el nivel de conocimiento, la utilidad percibida, las barreras institucionales y la disposición a su incorporación en la práctica clínica. La metodología incluyó un estudio descriptivo de corte transversal con enfoque mixto. Se aplicó el Cuestionario de Percepción, Conocimiento y Actitudes del Personal Médico frente al Uso de IA en Oncología (V1.0), instrumento de elaboración propia con 20 ítems Likert distribuidos en cuatro dimensiones y cuatro preguntas abiertas. La validez de contenido se evaluó mediante el coeficiente V de Aiken ($n = 6$ expertos) y la consistencia interna con alfa de Cronbach. El análisis cuantitativo empleó estadísticos descriptivos, pruebas de Shapiro-Wilk, U de Mann-Whitney, Kruskal-Wallis y correlación Rho de Spearman ($\alpha = 0,05$). El componente cualitativo se procesó mediante análisis temático reflexivo. Participaron 23 profesionales médicos (65,2% mujeres; 52,2% oncólogos). El instrumento demostró validez de contenido alta (V de Aiken global = 0,924; IC 95%: 0,692–1,000) y consistencia interna excelente ($\alpha = 0,937$). La dimensión Expectativas obtuvo el puntaje más alto ($M = 19,3/25$), mientras que Conocimiento registró el

más bajo ($M = 15,8/25$). El ítem con menor media fue B8, capacitación formal recibida en IA, ($M = 2,57$). Se identificó una correlación muy fuerte entre Utilidad y Expectativas ($p = 0,894$; $p < 0,001$) y ausencia de correlación entre Conocimiento y Barreras ($p = 0,079$; $p = 0,722$). No se encontraron diferencias significativas por sexo, categoría profesional ni años de experiencia ($p > 0,05$). El análisis temático reveló que la disposición a adoptar IA está condicionada a supervisión médica permanente, capacitación específica e infraestructura adecuada. El personal médico del HECAM muestra alta predisposición hacia la IA en oncología, pero enfrenta una brecha formativa real y barreras estructurales independientes del nivel de conocimiento individual. El instrumento V1.0 validado constituye una herramienta replicable para estudios multicéntricos futuros.

Palabras clave: Inteligencia artificial, Neoplasias de la mama, Percepción del personal de salud, Toma de decisiones, Cáncer de mama.

Abstract

The objective was to analyze the perceptions of medical staff at the Carlos Andrade Marín Specialty Hospital (HECAM) regarding the use of artificial intelligence (AI) in breast cancer management, exploring their level of knowledge, perceived usefulness, institutional barriers, and willingness to incorporate it into

clinical practice. The methodology included a descriptive, cross-sectional study with a mixed-methods approach. The Questionnaire on Perception, Knowledge, and Attitudes of Medical Staff Regarding the Use of AI in Oncology (V1.0), a self-developed instrument with 20 Likert-scale items distributed across four dimensions and four open-ended questions, was administered. Content validity was assessed using Aiken's V coefficient ($n = 6$ experts), and internal consistency was evaluated using Cronbach's alpha. Quantitative analysis employed descriptive statistics, Shapiro-Wilk tests, Mann-Whitney U tests, Kruskal-Wallis tests, and Spearman's rho correlation ($\alpha = 0.05$). The qualitative component was processed using reflective thematic analysis. Twenty-three medical professionals participated (65.2% women; 52.2% oncologists). The instrument demonstrated high content validity (overall Aiken's V = 0.924; 95% CI: 0.692–1.000) and excellent internal consistency ($\alpha = 0.937$). The Expectations dimension obtained the highest score ($M = 19.3/25$), while Knowledge registered the lowest ($M = 15.8/25$). The item with the lowest mean was B8, formal training received in AI ($M = 2.57$). A very strong correlation was identified between Utility and Expectations ($\rho = 0.894$; $p < 0.001$), and no correlation was found between Knowledge and Barriers ($\rho = 0.079$; $p = 0.722$). No significant differences were found by sex, professional category, or years of experience ($p > 0.05$). Thematic analysis revealed that the willingness to adopt AI is contingent upon ongoing medical supervision, specific training, and adequate infrastructure. Medical staff at HECAM show a high predisposition toward AI in oncology, but face a real training gap and structural barriers independent of individual knowledge levels. The validated V1.0 instrument constitutes a replicable tool for future multicenter studies.

Keywords: Artificial intelligence, Breast neoplasms, Healthcare staff perception, Decision-making, Breast cancer.

Sumário

O objetivo deste estudo foi analisar as percepções da equipe médica do Hospital de

Especialidades Carlos Andrade Marín (HECAM) sobre o uso da inteligência artificial (IA) no manejo do câncer de mama, explorando seu nível de conhecimento, utilidade percebida, barreiras institucionais e disposição para incorporá-la à prática clínica. A metodologia incluiu um estudo descritivo transversal com abordagem mista. Foi aplicado o Questionário sobre Percepção, Conhecimento e Atitudes da Equipe Médica em Relação ao Uso da IA em Oncologia (V1.0), um instrumento desenvolvido pelos pesquisadores, com 20 itens em escala Likert distribuídos em quatro dimensões e quatro questões abertas. A validade de conteúdo foi avaliada pelo coeficiente V de Aiken ($n = 6$ especialistas) e a consistência interna pelo alfa de Cronbach. A análise quantitativa empregou estatística descritiva, testes de Shapiro-Wilk, testes U de Mann-Whitney, testes de Kruskal-Wallis e correlação de Spearman ($\alpha = 0,05$). A componente qualitativa foi processada por meio de análise temática reflexiva. Vinte e três profissionais da área médica participaram do estudo (65,2% mulheres; 52,2% oncologistas). O instrumento demonstrou alta validade de conteúdo (V de Aiken geral = 0,924; IC 95%: 0,692–1,000) e excelente consistência interna ($\alpha = 0,937$). A dimensão Expectativas obteve a maior pontuação ($M = 19,3/25$), enquanto Conhecimento registrou a menor ($M = 15,8/25$). O item com a menor média foi B8, treinamento formal recebido em IA ($M = 2,57$). Uma correlação muito forte foi identificada entre Utilidade e Expectativas ($\rho = 0,894$; $p < 0,001$), e nenhuma correlação foi encontrada entre Conhecimento e Barreiras ($\rho = 0,079$; $p = 0,722$). Não foram encontradas diferenças significativas por sexo, categoria profissional ou anos de experiência ($p > 0,05$). A análise temática revelou que a disposição para adotar a IA depende da supervisão médica contínua, do treinamento específico e de infraestrutura adequada. A equipe médica do HECAM demonstra uma alta predisposição à IA em oncologia, mas enfrenta uma lacuna real de treinamento e barreiras estruturais independentes do nível de conhecimento individual. O instrumento validado na versão

1.0 constitui uma ferramenta replicável para futuros estudos multicêntricos.

Palavras-chave: Inteligência artificial, Neoplasias da mama, Percepção da equipe de saúde, Tomada de decisão, Câncer de mama.

Introducción

La inteligencia artificial (IA) ha emergido como una herramienta transformadora en la medicina contemporánea, con un impacto particularmente significativo en el campo de la oncología. Esta tecnología, fundamentada en algoritmos de aprendizaje profundo (deep learning), ha demostrado capacidad para reducir la variabilidad inter observador en la interpretación de estudios diagnósticos por imagen (Montero & Silva, 2025). Más allá de la optimización diagnóstica, la IA facilita la personalización de esquemas terapéuticos mediante el procesamiento de datos genómicos y morfológicos masivos a través del aprendizaje automático (machine learning), lo que resulta especialmente relevante para mejorar las brechas de atención en países de recursos limitados (Cazap y De Celis, 2024; Tannia y Rivera, 2024).

En este ámbito, las redes neuronales convolucionales han demostrado superar a los sistemas convencionales como la detección asistida por computadora (CAD), alcanzando una especificidad de hasta el 98% en la identificación de lesiones malignas en muestras histopatológicas y estudios de imagen mamaria (Narciso y Alcívar, 2026). Este avance tecnológico posibilita la transición hacia una medicina de precisión orientada a optimizar el flujo de trabajo clínico y priorizar la calidad de atención al paciente oncológico (Ashif Khan et al., 2026; Salazar et al., 2026). En el contexto ecuatoriano, el escenario epidemiológico revela un incremento progresivo de neoplasias asociadas con los cambios en el estilo de vida y el envejecimiento poblacional. El cáncer de

mama se ha consolidado como la patología de mayor incidencia y mortalidad en mujeres ecuatorianas con una tasa de incidencia de 35,2 por cada 100.000 mujeres y una mortalidad de 12,4 por cada 100.000 habitantes (Colegio de Médicos de Pichincha, 2026; Maldonado-Noboa et al., 2025). A nivel regional, SOLCA Núcleo de Tungurahua reportó 287 nuevos casos de cáncer de mama, lo que evidencia una creciente presión asistencial en los centros de referencia oncológica (Solca, 2025). Esta realidad se agrava por un déficit crítico de talento humano especializado: el país dispone de aproximadamente 1,2 oncólogos por cada 100.000 habitantes, cifra que se encuentra muy por debajo de los estándares internacionales, con una concentración desproporcionada de especialistas en Quito y Guayaquil que acentúa la disparidad geográfica en el acceso a tratamientos oportunos (Villacrés et al., 2018). Ante este panorama, la integración de la IA se presenta como una estrategia viable para descentralizar y fortalecer la atención oncológica, siempre que se garantice la infraestructura y la capacitación del personal necesarias para su implementación efectiva (Maldonado et al., 2025).

No obstante, la adopción de la IA en oncología no depende exclusivamente de su rendimiento técnico, sino de una compleja interacción de factores psicosociales y estructurales (Salazar-Garcés et al., 2026). El Modelo de Aceptación Tecnológica (TAM) postula que la intención de uso por parte del personal médico está condicionada por la utilidad percibida y la facilidad de uso de la herramienta (QI, 2026). La Política Nacional de Transformación Digital del Ecuador reconoce que la integración eficaz de estas tecnologías requiere una reconfiguración de los flujos de trabajo institucionales para evitar que su implementación sea percibida como una carga

adicional (Ministerio de Salud Pública del Ecuador, 2024; QI, 2026). A nivel internacional, se ha documentado que el 73% de las instituciones oncológicas postergan la incorporación de IA debido a barreras estructurales como infraestructura insuficiente, costos elevados y deficiencia en programas de capacitación acreditados (ESMO Daily Reporter, 2025). A ello se suma la resistencia profesional derivada del temor a la pérdida de autonomía clínica y a la deshumanización del vínculo médico-paciente, factores que refuerzan la necesidad de concebir a la IA como un elemento potenciador del juicio clínico y no como su sustituto (Trujillo, 2026).

A pesar de la relevancia de esta temática, en Ecuador existe una marcada ausencia de estudios sistemáticos que evalúen la percepción y la disposición del personal médico oncológico hacia estas tecnologías emergentes (Guzmán, 2024). La adopción de la IA en el entorno clínico nacional no ha sido analizada con el rigor suficiente para comprender las limitaciones del sistema en la optimización de recursos asistenciales (Guzmán, 2024; Ramírez et al., 2024). La literatura señala que la percepción positiva y la facilidad de uso constituyen determinantes críticos para el rendimiento adecuado de estas herramientas y la mejora del estándar de atención médica (Yáñez et al., 2025). En este marco, la Organización Panamericana de la Salud ha enfatizado la importancia de promover estándares éticos y transparentes que guíen la transformación digital en salud, asegurando la supervisión humana obligatoria y el respeto a la equidad sanitaria (OPS, 2021).

En consecuencia, el objetivo de esta investigación fue analizar la percepción del personal médico del Hospital de Especialidades Carlos Andrade Marín acerca de la implementación de herramientas de inteligencia

artificial en el manejo del cáncer de mama, explorando el nivel de conocimiento, la utilidad percibida, las barreras institucionales y la disposición hacia su incorporación en la práctica clínica oncológica.

Materiales y Métodos

Se realizó un estudio descriptivo de corte transversal con enfoque mixto. El componente cuantitativo fue predominante y se complementó con cuatro preguntas abiertas para explorar perspectivas que la escala Likert no captura por sí sola. La recolección de datos se llevó a cabo durante el primer trimestre de 2026 en el Hospital de Especialidades Carlos Andrade Marín (HECAM), previa aprobación del Comité de Ética de Investigación en Seres Humanos de la Universidad Técnica de Ambato (CEISH-UTA). Participaron 23 profesionales médicos (15 mujeres, 8 hombres) mediante muestreo no probabilístico por conveniencia. El 52,2% correspondió a oncólogos, el 21,7% a médicos especialistas, el 17,4% a residentes y el 8,7% a otras categorías profesionales. La mayoría trabajaba en hospital público (91,3%), con un rango de experiencia clínica de 1 a más de 12 años. Todos firmaron el consentimiento informado previamente.

Se utilizó el Cuestionario de Percepción, Conocimiento y Actitudes del Personal Médico frente al Uso de Inteligencia Artificial en Oncología (V1.0), de elaboración propia. Consta de seis ítems sociodemográficos (Sección A), veinte ítems tipo Likert de cinco opciones distribuidos en cuatro dimensiones (Sección B–E) y cuatro preguntas abiertas (Sección F). Las dimensiones miden: conocimiento sobre IA en salud (ítems 7–11), percepción de utilidad y confianza (ítems 12–16), barreras y limitaciones percibidas (ítems 17–21), y expectativas y disposición a adoptar IA (ítems 22–26). Las puntuaciones por dimensión oscilan entre 5 y 25 puntos. La

validez de contenido se evaluó mediante juicio de expertos ($n = 6$) con formación en tecnologías de la información, oncología clínica, medicina familiar y metodología de la investigación. Cada experto calificó los 24 ítems del instrumento (20 Likert + 4 preguntas abiertas) según cuatro criterios: pertinencia, claridad, coherencia y adecuación clínica, empleando una escala de 1 a 4. Se calculó el coeficiente V de Aiken para cada ítem y criterio, con intervalos de confianza al 95% según el método de Penfield y Giacobbi (1). Se estableció un umbral de aceptabilidad de $V \geq 0,80$.

Todos los ítems superaron el umbral establecido, con valores entre $V = 0,833$ y $V = 1,000$. El coeficiente global del instrumento fue $V = 0,924$ (IC 95%: 0,692–1,000). Por dimensiones: conocimiento ($V = 0,933$), utilidad y confianza ($V = 0,922$), barreras ($V = 0,919$) y expectativas ($V = 0,922$). La suficiencia de los ítems por dimensión fue valorada de forma global por cada experto en escala 1–4. Las medias resultantes indicaron suficiencia adecuada en cuatro dimensiones (conocimiento: 3,50; utilidad: 3,83; expectativas: 3,83; preguntas abiertas: 3,83), mientras que la dimensión de barreras obtuvo 3,17, calificada como parcialmente suficiente. A partir de las observaciones recibidas se ajustó la redacción de cinco ítems (B9, C15, D21, E25 y E26) antes de la aplicación definitiva. La concordancia entre expertos se analizó con el coeficiente W de Kendall, aplicado por separado a cada dimensión sobre los promedios de los cuatro criterios de evaluación. Los resultados fueron bajos y estadísticamente no significativos en las cuatro dimensiones: conocimiento ($W = 0,222$; $\chi^2(3) = 4,000$; $p = 0,261$), utilidad y confianza ($W = 0,222$; $\chi^2(3) = 4,000$; $p = 0,261$), barreras ($W = 0,167$; $\chi^2(3) = 3,000$; $p = 0,392$) y expectativas ($W = 0,222$;

$\chi^2(3) = 4,000$; $p = 0,261$). Estos valores responden al efecto techo observado en las puntuaciones —la mayoría de los expertos asignó la calificación máxima (4/4) en todos los criterios—, lo que reduce la varianza de rangos que el estadístico requiere para detectar concordancia ordinal. El fenómeno es coherente con los altos valores de V de Aiken obtenidos.

El cuestionario se aplicó de forma presencial entre enero y marzo de 2026. Los participantes fueron abordados durante sus turnos asistenciales; se explicaron los objetivos del estudio y se entregó el instrumento impreso junto con el formulario de consentimiento informado. Se revisó la completitud de cada cuestionario antes de su inclusión. No se registraron datos faltantes en los ítems Likert. El análisis cuantitativo se realizó con IBM SPSS Statistics v. 31. La consistencia interna del instrumento se evaluó mediante el alfa de Cronbach global y por dimensión. La distribución de los puntajes se exploró con la prueba de Shapiro-Wilk dado el tamaño muestral ($n < 30$); ante la ausencia de normalidad, se aplicaron pruebas no paramétricas.

Para las comparaciones entre dos grupos independientes se empleó la U de Mann-Whitney, y para tres o más grupos la prueba de Kruskal-Wallis con post hoc de Dunn corregido por Bonferroni cuando el resultado fue significativo. Las correlaciones entre dimensiones se estimaron con el coeficiente Rho de Spearman. El nivel de significancia fue $\alpha = 0,05$. Las variables sociodemográficas se describieron con frecuencias absolutas y porcentajes. El componente cualitativo (preguntas abiertas F1–F4) se analizó mediante análisis temático reflexivo según la propuesta de Braun y Clarke (2) en seis fases: familiarización con los datos, codificación inicial, búsqueda de temas, revisión, definición

y redacción. Los temas emergentes se contrastaron con los hallazgos cuantitativos para identificar convergencias y divergencias. El protocolo fue aprobado por el CEISH-UTA. La participación fue voluntaria; todos los sujetos firmaron el consentimiento informado. Los datos se codificaron con identificadores alfanuméricos para preservar el anonimato.

Resultados y Discusión

La Tabla 1 describe las características de los 23 profesionales médicos que participaron en el estudio. El grupo etario predominante fue el de

30 a 39 años (47,8 %), con una edad media de 38,7 años (DE = 8,4). El 65,2 % de los participantes fueron mujeres. Los oncólogos constituyeron la mayoría (52,2 %), seguidos de médicos especialistas (21,7 %) y residentes (17,4 %). La mayor parte trabajaba en hospital público (91,3 %). Los años de experiencia clínica se distribuyeron predominantemente entre los rangos de 4 a 12 años (65,2 %), mientras que la experiencia específica en oncología mostró mayor variabilidad, con el 26,1 % en el rango de 1 a 3 años.

Tabla 1. Características sociodemográficas y profesionales de los participantes (n = 23).

Variable	n	%	M (DE)	Md (RIQ)
Grupo de edad				
20–29 años	1	4.3	38,7 (8,4)	40 (33–47)
30–39 años	11	47.8	—	—
40–49 años	9	39.1	—	—
50–59 años	2	8.7	—	—
Sexo				
Femenino	15	65.2	—	—
Masculino	8	34.8	—	—
Categoría profesional				
Oncólogo/a	12	52.2	—	—
Médico/a especialista	5	21.7	—	—
Médico/a residente	4	17.4	—	—
Otro	2	8.7	—	—
Años de experiencia clínica				
1–3 años	2	8.7	—	—
4–7 años	7	30.4	—	—
8–12 años	8	34.8	—	—
> 12 años	6	26.1	—	—
Años de experiencia en oncología				
1–3 años	6	26.1	—	—
4–7 años	8	34.8	—	—
8–12 años	4	17.4	—	—
> 12 años	5	21.7	—	—
Tipo de institución				
Hospital público (HECAM)	21	91.3	—	—
Otro	2	8.7	—	—

Nota. M = media; DE = desviación estándar; Md = mediana; RIQ = rango intercuartílico. Los valores de M (DE) y Md (RIQ) se reportan únicamente para la variable edad, dado que las demás son categóricas. HECAM = Hospital de Especialidades Carlos Andrade Marín

Fuente: Elaboración propia.

La validez y confiabilidad del Cuestionario de Percepción, Conocimiento y Actitudes del Personal Médico frente al Uso de Inteligencia Artificial en Oncología (V1.0) fueron evaluadas mediante tres estrategias complementarias: (a) validez de contenido a través del coeficiente V de Aiken con juicio de expertos, (b) concordancia inter-evaluadores mediante el coeficiente W de Kendall, y (c) suficiencia por

dimensión según criterio de los seis expertos consultados. La validación de contenido fue realizada por un panel de seis expertos (n = 6), seleccionados por conveniencia y criterio de especialización en las áreas relevantes para el estudio: tecnologías de la información aplicadas a salud, oncología clínica, medicina familiar, bioestadística y metodología de la investigación. Sus perfiles se presentan en la

Tabla 2. La validez de contenido fue cuantificada mediante el coeficiente V de Aiken (Aiken, 1985), calculado para cada ítem y criterio según la fórmula $V = S / [n (c - 1)]$,

donde $S = \Sigma(\text{puntuación} - 1)$, n = número de expertos (6) y c = número de categorías de la escala (4). Los resultados se presentan en las Tablas 3 y 4.

Tabla 2. Perfil del panel de expertos consultados para la validación de contenido.

Código	Formación / Cargo	Institución	Área	Años exp.
E2	PhD. Tecnologías de la Información	ESFORSE - UTA	Tecnologías de la Información	22
E3	PhD. Tecnologías de la Información aplicadas a salud	UTA - FISEI	Ciencias de la Decisión	15
E4	Médico Especialista	UTA	Medicina Familiar y Comunitaria	12
E5	Médico Especialista	Universidad Indoamérica	Medicina Familiar	7
E6	Médico	UTA	Medicina	8
E7	Médico Especialista	UTA / Consulta privada	Emergencia y Desastres	11

Fuente: Elaboración propia.

Tabla 3. Coeficiente V de Aiken por ítem y criterio de evaluación ($n = 6$ expertos).

Ítem	Dimensión	V Pertinencia	V Claridad	V Coherencia	V Adecuación	V Ítem	IC 95%	Decisión
B7	Conocimiento	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
B8	Conocimiento	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
B9	Conocimiento	0.944	0.944	0.944	0.889	0.931	0.708–1.000	Válido
B10	Conocimiento	0.944	0.889	0.889	0.889	0.903	0.643–1.000	Válido
B11	Conocimiento	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
C12	Utilidad	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
C13	Utilidad	0.944	0.944	1.000	1.000	0.972	0.828–1.000	Válido
C14	Utilidad	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
C15	Utilidad	0.944	0.944	0.944	0.833	0.917	0.674–1.000	Válido
C16	Utilidad	0.833	0.833	0.833	0.833	0.833	0.507–1.000	Válido
D17	Barreras	1.000	1.000	1.000	1.000	1.000	0.900–1.000	Válido
D18	Barreras	0.889	0.889	0.889	0.889	0.889	0.613–1.000	Válido
D19	Barreras	0.889	0.889	0.889	0.889	0.889	0.613–1.000	Válido
D20	Barreras	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
D21	Barreras	0.889	0.889	0.889	0.833	0.875	0.585–1.000	Válido
E22	Expectativas	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
E23	Expectativas	1.000	1.000	1.000	1.000	1.000	0.900–1.000	Válido
E24	Expectativas	0.944	0.944	0.944	0.944	0.944	0.744–1.000	Válido
E25	Expectativas	0.889	0.889	0.889	0.833	0.875	0.585–1.000	Válido
E26	Expectativas	0.833	0.944	0.833	0.778	0.847	0.532–1.000	Válido

Fuente: Elaboración propia.

Todos los ítems del instrumento superaron el umbral de aceptabilidad establecido ($V \geq 0,80$), con valores entre $V = 0,833$ (ítems C16 y E26) y $V = 1,000$ (ítems D17 y E23). Los valores más bajos se concentraron en ítems relacionados con la contextualización institucional (C16, E26) y la adecuación de enunciados con especificidad clínica (B10, D21, E25). El resumen de los coeficientes V de Aiken por dimensión y el valor global del instrumento se presenta en la Tabla 4. Todas las dimensiones alcanzaron valores de V de Aiken superiores a 0,90: Conocimiento ($V = 0,933$), Utilidad ($V =$

0,922), Barreras ($V = 0,919$) y Expectativas ($V = 0,922$). El coeficiente global del instrumento fue $V = 0,924$ (IC 95%: 0,692–1,000), indicando alta concordancia de contenido entre los expertos evaluadores. Los expertos valoraron la suficiencia de cada dimensión del instrumento en escala 1–4. Los resultados se presentan en la Tabla 5. Cuatro de las cinco dimensiones fueron calificadas como suficientes (promedio $\geq 3,50$). La dimensión Barreras y limitaciones percibidas obtuvo $M = 3,17$ (parcialmente suficiente), lo que se explica por las evaluaciones de los expertos E3

(puntuación = 2) y E6 (puntuación = 1), quienes sugirieron ampliar la cobertura de ítems relacionados con obstáculos estructurales e institucionales. A partir de las observaciones

recibidas se ajustó la redacción de cinco ítems (B9, C15, D21, E25 y E26) antes de la aplicación definitiva.

Tabla 4. *Coeficiente V de Aiken por dimensión y valor global del instrumento.*

Dimensión	N ítems	V de Aiken	IC inf. 95%	IC sup. 95%	Interpretación
B. Conocimiento sobre IA en salud	5	0.933	0.715	1.000	Alta concordancia
C. Percepción de utilidad y confianza	5	0.922	0.687	1.000	Alta concordancia
D. Barreras y limitaciones percibidas	5	0.919	0.681	1.000	Alta concordancia
E. Expectativas y disposición a adoptar IA	5	0.922	0.687	1.000	Alta concordancia
GLOBAL (B7–E26)	20	0.924	0.692	1.000	Alta concordancia

Fuente: Elaboración propia.

Tabla 5. *Evaluación de suficiencia por dimensión según criterio del panel de expertos.*

Dimensión	E2	E3	E4	E5	E6	E7	Promedio	Suficiencia
B. Conocimiento sobre IA en salud	4	3	4	4	2	4	3.50	Suficiente
C. Percepción de utilidad y confianza	4	3	4	4	4	4	3.83	Suficiente
D. Barreras y limitaciones percibidas	4	2	4	4	1	4	3.17	Parcialmente suficiente
E. Expectativas y disposición a adoptar IA	4	3	4	4	4	4	3.83	Suficiente
Preguntas abiertas (cobertura)	4	3	4	4	4	4	3.83	Suficiente

Fuente: Elaboración propia.

La concordancia entre los seis expertos se evaluó mediante el coeficiente W de Kendall, aplicado de forma independiente a cada

dimensión. Los resultados se presentan en la Tabla 6.

Tabla 6. *Concordancia inter-evaluadores: Coeficiente W de Kendall por dimensión (n = 6 expertos).*

Dimensión	Pertinencia	Claridad	Coherencia	Adecuación	N	W	χ^2	gl	p	Interpretación
B. Conocimiento sobre IA en salud	2.83	2.50	2.50	2.17	6	0.222	4.000	3	0.261	Concordancia baja (n.s.)
C. Percepción de utilidad y confianza	2.50	2.50	2.83	2.17	6	0.222	4.000	3	0.261	Concordancia baja (n.s.)
D. Barreras y limitaciones percibidas	2.58	2.58	2.58	2.25	6	0.167	3.000	3	0.392	Concordancia baja (n.s.)
E. Expectativas y disposición a adoptar IA	2.50	2.83	2.50	2.17	6	0.222	4.000	3	0.261	Concordancia baja (n.s.)

Fuente: Elaboración propia.

Los resultados indicaron una concordancia baja y estadísticamente no significativa en las cuatro dimensiones ($p > 0,05$ en todos los casos). Estos valores responden al efecto techo observado en las puntuaciones, la mayoría de los expertos asignó la calificación máxima (4/4) en todos los criterios—, lo que restringe la varianza de

rangos que el estadístico requiere para detectar concordancia ordinal. El fenómeno es coherente con los altos valores del V de Aiken obtenidos y no refleja desacuerdo sustantivo entre los evaluadores. La consistencia interna del instrumento fue evaluada con el coeficiente alfa de Cronbach global y por dimensión. Los

resultados se presentan en la Tabla 7. Todas las dimensiones del instrumento presentaron consistencia interna buena a excelente. El alfa

de Cronbach global fue $\alpha = 0,937$ (IC 95%: 0,872–0,963).

Tabla 7. Consistencia interna del instrumento: Coeficiente alfa de Cronbach por dimensión y global

Dimensión	k	α de Cronbach	IC 95%	Interpretación	n
B. Conocimiento sobre IA en salud	5	0.823	0.628–0.903	Buena	23
C. Percepción de utilidad y confianza	5	0.928	0.849–0.961	Buena	23
D. Barreras y limitaciones percibidas	5	0.827	0.636–0.905	Buena	23
E. Expectativas y disposición a adoptar IA	5	0.947	0.888–0.971	Buena	23
Global (B7–E26)	20	0.937	0.872–0.963	Buena	23

Fuente: Elaboración propia.

La dimensión Expectativas obtuvo el valor más alto ($\alpha = 0,947$), seguida de Utilidad y confianza ($\alpha = 0,928$). Conocimiento y Barreras alcanzaron consistencia buena ($\alpha = 0,823$ y $\alpha = 0,827$, respectivamente). Estos resultados confirman la confiabilidad del instrumento para

medir los constructos propuestos. La Tabla 8 presenta la distribución de los puntajes por dimensión y los resultados de la prueba de normalidad de Shapiro-Wilk.

Tabla 8. Estadísticos descriptivos por dimensión y prueba de normalidad de Shapiro-Wilk ($n = 23$)

Dimensión	M	DE	Mediana	RIQ	Mín	Máx	W	p
B. Conocimiento sobre IA en salud	15.8	4.4	15.0	13.5–19.5	6	25	0.972	0.736
C. Percepción de utilidad y confianza	16.6	4.9	18.0	14.0–20.0	5	25	0.956	0.384
D. Barreras y limitaciones percibidas	19.1	4.2	20.0	16.0–22.0	10	25	0.949	0.282
E. Expectativas y disposición a adoptar	19.3	4.8	20.0	15.0–25.0	10	25	0.894	0,019*
Score total (B7–E26)	70.8	14.8	66.0	63.5–82.5	35	96	0.952	0.317

Fuente: Elaboración propia.

Tabla 9. Estadísticos descriptivos por ítem del instrumento (escala Likert 1–5, $n = 23$).

Ítem	Enunciado	M	DE	Md	Mo	Mín	Máx
B7	Conozco conceptos básicos de IA aplicada a la salud.	3.43	0.84	3.0	3	2	5
B8	He recibido capacitación formal sobre IA aplicada a medic...	2.57	1.16	3.0	3	1	5
B9	Comprendo cómo la IA puede complementar la toma de decisi...	3.39	1.27	4.0	4	1	5
B10	Conozco ejemplos reales de aplicación de IA en oncología.	3.30	1.18	3.0	3	1	5
B11	Soy capaz de interpretar resultados generados por sistema...	3.09	1.20	3.0	3	1	5
C12	La IA puede mejorar la precisión diagnóstica.	3.57	1.12	4.0	4	1	5
C13	La IA optimiza tiempos de diagnóstico y tratamiento.	3.65	1.19	4.0	4	1	5
C14	Confío en los resultados generados por sistemas de IA.	2.96	1.02	3.0	3	1	5
C15	La IA puede reducir errores clínicos.	3.00	1.09	3.0	3	1	5
C16	La IA puede integrarse de forma efectiva en la oncología	3.39	1.08	3.0	3	1	5
D17	La falta de capacitación es una barrera importante para ...	3.96	1.19	4.0	5	1	5
D18	La IA podría disminuir la autonomía del profesional de ...	3.70	1.18	4.0	4	1	5
D19	Desconfío de resultados automatizados sin supervisión méd...	3.83	1.07	4.0	5	2	5
D20	Existen limitaciones tecnológicas para implementar IA en ...	3.87	1.10	4.0	5	2	5
D21	La infraestructura digital actual no es suficiente para I...	3.78	0.95	4.0	4	2	5
E22	Estoy dispuesto a incorporar IA en mi práctica clínica.	3.96	0.98	4.0	5	2	5
E23	Considero necesaria una capacitación formal en IA oncológ...	4.13	0.92	4.0	5	2	5
E24	La IA mejorará la calidad de las decisiones clínicas.	3.70	1.02	3.0	3	2	5
E25	La IA incrementará la calidad de atención en oncología.	3.52	1.27	3.0	3	1	5
E26	Tengo interés en capacitarme específicamente en IA aplica...	4.04	1.02	4.0	5	2	5

Fuente: Elaboración propia.

La dimensión Expectativas obtuvo la media más alta ($M = 19,3$; $DE = 4,8$), seguida de Barreras ($M = 19,1$; $DE = 4,2$). El menor puntaje promedio correspondió a Conocimiento

sobre IA ($M = 15,8$; $DE = 4,4$). La prueba de Shapiro-Wilk indicó distribución normal en cuatro de las cinco medidas; únicamente Expectativas mostró desviación significativa

($W = 0,894$; $p = 0,019$). Dado el tamaño muestral reducido y la presencia de al menos una dimensión no normal, se aplicaron pruebas no paramétricas para todos los análisis inferenciales. El análisis ítem por ítem (Tabla 9) reveló que el ítem con mayor puntuación media fue E23 («Considero necesaria una capacitación formal en IA oncológica»; $M = 4,13$; $DE = 0,92$), seguido de E26 ($M = 4,04$) y E22 ($M = 3,96$). El ítem con menor puntuación

fue B8 («He recibido capacitación formal sobre IA»; $M = 2,57$; $DE = 1,16$), evidencia directa de la brecha formativa existente. Dentro de la dimensión Utilidad, los ítems C14 y C15 presentaron las medias más bajas ($M = 2,96$ y $3,00$ respectivamente), indicando reservas sobre la confianza en los resultados de la IA. La Tabla 10 presenta los resultados de la prueba U de Mann-Whitney para la comparación de puntajes según sexo.

Tabla 10. Comparación de puntajes por sexo: Prueba U de Mann-Whitney ($n = 23$)

Dimensión	Md Femenino ($n = 15$)	Md Masculino ($n = 8$)	U	p	r
B. Conocimiento	15.0	16.0	51	0.581	0.115
C. Utilidad	16.0	18.0	62	0.897	0.027
D. Barreras	20.0	19.5	66	0.721	0.074
E. Expectativas	19.0	20.5	54	0.717	0.076
Score total	66.0	72.5	60	1.000	0.000

Fuente: Elaboración propia.

No se encontraron diferencias estadísticamente significativas en ninguna dimensión según el sexo de los participantes ($p > 0,05$). Los tamaños de efecto fueron triviales a pequeños ($r = 0,000-0,115$), sugiriendo que la percepción

sobre la IA no difiere entre hombres y mujeres en esta muestra. La Tabla 11 presenta los resultados de la prueba de Kruskal-Wallis para la comparación de puntajes según la categoría profesional de los participantes.

Tabla 11. Comparación de puntajes según categoría profesional: Prueba de Kruskal-Wallis ($n = 23$).

Dimensión	Onc. ($n=12$)	Esp. ($n=5$)	Res. ($n=4$)	H ($gl=3$)	p	η^2
B. Conocimiento	15.0	15.0	19.5	17.500	2.626	0.453
C. Utilidad	18.0	15.0	19.0	13.000	4.381	0.223
D. Barreras	21.0	16.0	20.5	18.000	3.016	0.389
E. Expectativas	22.5	15.0	20.5	17.000	3.691	0.297
Score total	75.0	63.0	80.0	65.500	3.849	0.278

Fuente: Elaboración propia.

Ninguna comparación por categoría profesional alcanzó significancia estadística ($p > 0,05$). Sin embargo, los valores de η^2 sugieren efectos de tamaño moderado a grande en Utilidad ($\eta^2 = 0,199$) y Score total ($\eta^2 = 0,175$), lo que indica que con una muestra mayor estas diferencias podrían ser detectables. Los oncólogos mostraron la mediana más elevada en Expectativas ($Md = 22,5$), mientras que el grupo «Otro» presentó los puntajes más bajos en Conocimiento ($Md = 17,5$) y Score total ($Md = 65,5$). La Tabla 12 presenta los resultados de la prueba de Kruskal-Wallis para la comparación

de puntajes según los años de experiencia clínica. En la tabla 12 los años de experiencia clínica no mostraron asociación estadísticamente significativa con ninguna dimensión del instrumento ($p > 0,05$). Notablemente, la dimensión Barreras presentó el valor de H más bajo ($H = 0,443$; $p = 0,931$), indicando que la percepción sobre obstáculos para implementar IA es homogénea independientemente de la trayectoria profesional. La Tabla 13 presenta la matriz de correlaciones de Spearman entre las cuatro dimensiones del instrumento. La asociación más fuerte se observó entre Utilidad y confianza

y Expectativas ($p = 0,894$; $p < 0,001$), indicando que los participantes que perciben mayor

utilidad en la IA muestran mayor disposición a adoptarla.

Tabla 12. Comparación de puntajes según años de experiencia clínica: Prueba de Kruskal-Wallis ($n = 23$).

Dimensión	1-3 a. (n=2)	4-7 a. (n=7)	8-12 a. (n=8)	>12 a. (n=6)	H (gl=3)	p
B. Conocimiento	16.0	16.0	15.0	13.0	3.109	0.375
C. Utilidad	19.0	18.0	17.5	12.0	3.337	0.342
D. Barreras	20.0	21.0	20.0	19.5	0.443	0.931
E. Expectativas	20.0	23.0	19.5	14.5	2.171	0.538
Score total	75.0	79.0	66.0	55.0	2.573	0.462

Fuente: Elaboración propia.

Tabla 13. Correlaciones entre dimensiones del instrumento: Coeficiente Rho de Spearman ($n = 23$)

Dimensión	Conocimiento	Utilidad	Barreras	Expectativas
Conocimiento	—	+0,464*	+0,079	+0,494*
Utilidad	—	—	+0,499*	+0,894*
Barreras	—	—	—	+0,597*
Expectativas	—	—	—	—

Fuente: Elaboración propia.

Barreras correlacionó positivamente con Expectativas ($p = 0,597$; $p = 0,003$), sugiriendo que reconocer las limitaciones coexiste con la disposición a integrar la tecnología. La única correlación no significativa fue la de Conocimiento con Barreras ($p = 0,079$; $p = 0,722$): el nivel de familiaridad con la IA no predice la percepción de obstáculos institucionales. Conocimiento mostró correlaciones moderadas y significativas con Utilidad ($p = 0,464$) y Expectativas ($p = 0,494$). El análisis temático reflexivo (Braun y Clarke, 2006) de las cuatro preguntas abiertas reveló doce temas distribuidos en las dimensiones exploradas. La Tabla 14 presenta los temas principales, sus subtemas y citas representativas. El tema más frecuente fue la optimización diagnóstica (mencionado por 14 de 21 participantes): mejorar la precisión en imagen, reducir errores clínicos y acortar tiempos de diagnóstico. Un segundo grupo refirió el apoyo a la toma de decisiones mediante estadísticas de pronóstico y protocolos. Un tercer tema emergió en torno a la gestión y personalización del cuidado

oncológico. Solo un participante no identificó beneficios. La infraestructura tecnológica deficiente, conectividad, internet intermitente y equipos obsoletos, fue la barrera más mencionada (13 de 22 respuestas). El tiempo y la sobrecarga asistencial constituyeron el segundo eje temático. Un tercer tema agrupó barreras sistémicas y económicas: costos de implementación, procesos de aprobación y resistencia cultural. Las condiciones se articularon en tres temas. La capacitación formal y continua fue la más frecuente. La mejora de infraestructura y conectividad fue el segundo requisito más mencionado. Un tercer tema cualitativamente relevante emergió en torno a la necesidad de integración crítica con el juicio médico: los participantes demandan que el rol de la IA esté claramente delimitado como complementario al criterio clínico, y no como su sustituto. Las preocupaciones se organizaron en tres temas. La responsabilidad profesional ante errores algorítmicos fue la más frecuente. La deshumanización de la atención médica constituyó el segundo eje, especialmente sensible en oncología.

Tabla 14. Análisis temático de las preguntas abiertas: temas, subtemas y citas representativas.

Pregunta	Tema	Subtemas / códigos	Cita representativa
F1 Beneficios de la IA	Optimización diagnóstica	Diagnóstico oportuno, precisión en imagen, estadificación temprana	"Mejoraría el riesgo de errores en la práctica clínica con evidencia actualizada" (M023)
	Apoyo a la toma de decisiones	Estadísticas de pronóstico, guías de tratamiento, normalización de protocolos	"Ayuda de acuerdo a estadísticas, pronóstico y tratamiento" (M007)
	Gestión y personalización del cuidado	Manejo personalizado, optimización del flujo asistencial, planificación de atención	"Mejora el manejo personalizado" (M011); "Optimizar diagnóstico, tratamiento, disminuir errores clínicos" (M016)
F2 Barreras institucionales	Déficit de infraestructura tecnológica	Conectividad, internet fluctuante, equipos básicos, falta de TIC	"Internet adecuado / equipos de computación muy básicos" (M004); "El sistema de internet es fluctuante" (M018)
	Limitaciones de tiempo y carga asistencial	Sobrecarga laboral, tiempo insuficiente, espacio físico	"No hay espacio físico ni tiempo" (M006); "Tiempo" (M007, M017)
	Barreras sistémicas y económicas	Costos de implementación, aprobaciones institucionales, resistencia al cambio	"Aprobaciones en el sistema médico" (M012); "Los costos" (M016)
F3 Condiciones para adoptar	Capacitación formal y continua	Formación específica en IA, programas acreditados, capacitación en la práctica clínica	"Un adecuado estudio que permita integrar tecnología con conocimiento médico" (M015); "Capacitación continua" (M009)
	Mejora de infraestructura y conectividad	Internet estable en el trabajo, tecnología de punta, sistemas informáticos adecuados	"Tener internet en el trabajo" (M006); "Buen internet, tecnología de punta en todas las áreas" (M014)
	Integración crítica con el juicio médico	IA como complemento —no sustituto— del criterio clínico, confianza en resultados, herramientas intuitivas	"La IA no suplente el criterio médico, al contrario lo complementa; se requiere evidenciar la misión de la IA" (M020)
F4 Preocupaciones éticas	Responsabilidad profesional y errores algorítmicos	Fallas técnicas con impacto clínico, mal uso por personal no capacitado, ausencia de responsabilidad legal	"La tecnología puede fallar y llevar a malas decisiones" (M004); "No hay quien dé la cara a un error" (M006)
	Deshumanización de la atención médica	Pérdida del vínculo médico-paciente, despersonalización del diagnóstico, reducción del análisis humano	"Son seres humanos, no números" (M021); "Falta de acercamiento con el paciente oncológico en la consulta" (M023)
	Privacidad, normativa y gobernanza de datos	Manejo de datos sensibles, confidencialidad del paciente, falta de normativa regulatoria	"Confidencialidad a la información de determinado paciente" (M015); "Falta de normativa" (M017)

Fuente: Elaboración propia.

El tercer tema agrupó preocupaciones sobre privacidad, confidencialidad y ausencia de normativa específica en Ecuador. Seis participantes (26,1 %) indicaron no tener

preocupaciones éticas. La Tabla 15 presenta la triangulación entre los hallazgos cuantitativos y cualitativos del estudio por dimensión.

Tabla 15. Triangulación cuantitativa-cualitativa: convergencias y divergencias por dimensión

Dimensión cuantitativa	Hallazgo cuantitativo	Hallazgo cualitativo convergente	Relación
Conocimiento (B) M = 15,8; DE = 4,4	Puntaje más bajo entre las 4 dimensiones; B8 con la media más baja del instrumento (M = 2,57)	El personal identifica beneficios técnicos de la IA pero reconoce no haber recibido capacitación formal	Convergencia: la brecha formativa se confirma tanto en la escala como en las respuestas narrativas
Utilidad y confianza (C) M = 16,6; DE = 4,9	C14 «Confío en los resultados de la IA» presenta la media más baja de la dimensión (M = 2,96)	Varios participantes condicionan la adopción a evidencia científica robusta y auditoría de los sistemas	Convergencia: la confianza en la IA es moderada y está supeditada a validación clínica externa
Barreras (D) M = 19,1; DE = 4,2	Media alta en toda la dimensión; el conocimiento no se correlaciona con barreras ($p = 0,079$; $p = 0,722$)	Internet, infraestructura y tiempo emergen como barreras dominantes; percibidas como estructurales, no superables por formación individual	Convergencia y matiz: los datos cuantitativos reflejan alta percepción de barreras; los cualitativos precisan su naturaleza sistémica
Expectativas (E) M = 19,3; DE = 4,8	Correlación muy fuerte con Utilidad ($p = 0,894$); E23 ítem con mayor media del instrumento (M = 4,13)	El personal expresa alta disposición a capacitarse, pero condiciona la adopción a que la IA sea complementaria al juicio clínico, no sustituta	Convergencia con matiz ético: la predisposición es alta, pero supeditada al principio de supervisión médica permanente

Fuente: Elaboración propia.

La triangulación revela coherencia estructural entre los componentes del estudio. La brecha formativa identificada en Conocimiento, B8

con la media más baja del instrumento (M = 2,57), se confirma narrativamente en las respuestas abiertas. La ausencia de correlación

entre Conocimiento y Barreras ($p = 0,079$) adquiere sentido cualitativo: los obstáculos son percibidos como estructurales, no atribuibles a déficit de conocimiento individual. La dimensión con mayor riqueza interpretativa fue Expectativas: la correlación Utilidad-Expectativas ($p = 0,894$) y la media más alta del instrumento (E23, $M = 4,13$) se articulan con un matiz cualitativo crítico, la alta disposición está condicionada al principio de supervisión médica permanente y a que la herramienta no sea percibida como carga adicional en un sistema ya tensionado. Los hallazgos de esta prueba piloto describen un patrón que ha sido documentado de forma creciente en la literatura internacional: el personal médico reconoce el potencial transformador de la inteligencia artificial en oncología, muestra alta disposición a adoptarla, pero enfrenta una brecha formativa real y obstáculos estructurales que ningún nivel de motivación individual puede resolver por sí solo.

La dimensión de Conocimiento obtuvo la media más baja del instrumento ($M = 15,8$; $DE = 4,4$), con el ítem B8, referido específicamente a la recepción de capacitación formal en IA como el punto más crítico ($M = 2,57$; $DE = 1,16$). Este hallazgo coincide con lo reportado por Weidener y Fischer (2024) en una encuesta a 487 estudiantes de medicina de tres países de habla alemana, donde la educación formal en IA era mínima a pesar del creciente uso de herramientas basadas en esta tecnología. Simultáneamente, un estudio con médicos de Fibromialgia en el contexto de un congreso europeo ($n = 26$) evidenció que, pese a la experiencia clínica previa, la mayoría del personal se sentía insuficientemente preparado para integrar la IA en su práctica, identificando la capacitación dirigida como la condición más urgente para la adopción (Casella et al., 2024). La dimensión de Expectativas y disposición a

adoptar IA ($M = 19,3$; $DE = 4,8$) fue la más alta del instrumento, con E23 («Considero necesaria una capacitación formal en IA oncológica», $M = 4,13$) como el ítem de mayor puntuación. Lejos de contradecirse, estos dos extremos, bajo conocimiento, alta expectativa, representan la tensión característica del profesional médico que se enfrenta a una tecnología emergente en un sistema de salud con recursos limitados. Una encuesta a 1.692 médicos estadounidenses realizada por la American Medical Association en 2026 mostró que el 80% usa IA en contextos profesionales, el doble respecto a 2023—, pero que la formación continúa siendo la principal demanda (Association, 2026). En el contexto latinoamericano, solo tres países cuentan con programas públicos de formación en IA, y Ecuador no figura entre ellos (Regazzoni, 2024), lo que contextualiza el déficit formativo detectado en el HECAM como un problema sistémico regional, no una debilidad institucional aislada.

El hallazgo más relevante del estudio desde la perspectiva analítica es la ausencia de correlación entre Conocimiento y Barreras ($p = 0,079$; $p = 0,722$). Esto refuta la hipótesis implícita de que la capacitación resuelve los obstáculos: los médicos con mayor conocimiento de IA no perciben menos barreras que sus colegas con menor familiaridad. Una revisión de alcance con estudios publicados entre 2020 y 2023 sobre la implementación de tecnologías digitales en hospitales de países de ingresos bajos y medios (Yew et al., 2025) identificó que los obstáculos de infraestructura, conectividad e integración de sistemas son independientes del nivel de alfabetización digital del personal, lo que valida este hallazgo en el contexto del HECAM. La correlación muy fuerte entre Utilidad y confianza y Expectativas ($p = 0,894$; $p < 0,001$) es la relación más robusta del estudio y responde al

postulado central del Modelo de Aceptación Tecnológica (TAM): la intención de uso está determinada primariamente por la utilidad percibida (Kelly et al., 2019). Este vínculo ha sido replicado en entornos hospitalarios de distintas latitudes. En una encuesta con médicos de cuidados intensivos en Alemania ($n = 7.475$), la percepción de valor clínico fue el predictor más fuerte de la actitud favorable hacia los sistemas de IA (Giebel et al., 2026), en consonancia con el presente estudio. La Asociación Médica Estadounidense documentó en 2024 que el 65% de los médicos percibe una ventaja en el uso de IA para el cuidado de pacientes, cifra que ascendió al 76% en 2026 (Association, 2026); la progresión sugiere que la utilidad percibida sigue creciendo a medida que la evidencia clínica de la IA se acumula.

No obstante, la confianza en los resultados de la IA se mantiene como el eslabón débil de la cadena de aceptación (Salazar et al., 2026). Los ítems C14 («Confío en los resultados de sistemas de IA», $M = 2,96$) y C15 (La IA puede reducir errores clínicos», $M = 3,00$) reflejan un escepticismo técnicamente fundamentado, no un rechazo ideológico. Una encuesta a médicos de atención primaria y asistentes en Kansas ($n = 532$) identificó como preocupaciones principales los estándares no regulados (mediana = 4,0) y los problemas de responsabilidad legal (mediana = 4,0) (Dean et al., 2024), ambos relacionados con la confianza en la tecnología. En el mismo sentido, un estudio mixto con médicos polacos (Dean et al., 2024) encontró que el escepticismo ante la IA no proviene del desconocimiento, sino de una evaluación racional de las limitaciones actuales de los sistemas: riesgo de error, opacidad algorítmica y ausencia de marcos de gobernanza claros. La alta percepción de barreras estructurales (dimensión D, $M = 19,1$) es congruente con la situación de América

Latina, donde las inversiones privadas en tecnología digital para salud descendieron un 84% entre 2021 y 2023 (Regazzoni, 2024). Una revisión sistemática con metaanálisis sobre la adopción de tecnologías digitales en 91 estudios de países de ingresos bajos y medios (Wang et al., 2024) señaló que la infraestructura inadecuada, conectividad, software, equipos, es el obstáculo más consistentemente citado por los profesionales de salud, muy por encima de la resistencia personal.

En el contexto hospitalario ecuatoriano, donde el acceso a internet es intermitente y los sistemas informáticos tienen alta tasa de desactualización, esta percepción de barrera no es subjetiva sino objetivamente fundada. Elta wil et al. (2023) corroboran, en una revisión de alcance sobre adopción de IA en radiología, que la ausencia de infraestructura y de programas de capacitación acreditados son los dos factores que más consistentemente predicen la no adopción en instituciones de salud. La ausencia de diferencias estadísticamente significativas por sexo (U de Mann-Whitney, $p > 0,05$ en todas las dimensiones; $r = 0,000-0,115$) es coherente con estudios que señalan que el sexo no es un predictor robusto de la actitud hacia la IA en contextos donde el entorno institucional es homogéneo.

Una encuesta a 572 radiólogos europeos (Zanardo et al., 2024) no encontró diferencias sistemáticas por sexo en las expectativas sobre IA diagnóstica; los autores atribuyen esto a que la especialidad y el entorno clínico compartido son variables de mayor peso que el sexo individual. No obstante, un estudio con 156 oftalmólogos búlgaros identificó diferencias de sexo en la confianza diagnóstica (hombres más desconfiados; $p = 0,009$) (Radeva et al., 2026), lo que sugiere que el tamaño muestral del presente estudio ($n = 23$) puede no tener

potencia estadística suficiente para detectar diferencias de esa magnitud. La ausencia de diferencias por categoría profesional (Kruskal, $p > 0,05$) contrasta parcialmente con estudios donde la especialidad predice la actitud hacia la IA. Sin embargo, los tamaños de efecto moderados a grandes ($\eta^2 = 0,199$ para Utilidad; $\eta^2 = 0,175$ para Score total) indican que la ausencia de significancia es atribuible al tamaño muestral reducido más que a la inexistencia real de diferencias. Un estudio con médicos de atención primaria en Polonia (Mache et al., 2025) documentó que el rol profesional y la carga asistencial son mejores predictores de la actitud hacia la IA que la especialidad clínica per se, en entornos con presión asistencial elevada como el sistema público ecuatoriano, donde el tiempo emerge como barrera transversal a todas las categorías.

La validez de contenido del Cuestionario V1.0 se sustenta en tres pilares convergentes. El coeficiente V de Aiken, calculado con intervalos de confianza al 95% según Penfield y Giacobbi (Penfield y Giacobbi, 2004), garantiza que los valores obtenidos no son producto del azar sino del acuerdo técnico de un panel multidisciplinario de seis expertos. El umbral de $V \geq 0,80$ empleado es el estándar establecido en la literatura para fases exploratorias de validación de instrumento (Aiken, 1985). El valor global obtenido ($V = 0,924$) es comparable al reportado en estudios de validación de cuestionarios de percepción de IA en contextos académico-médicos, como el de Khojasteh et al., (2025) (Khojasteh et al., 2025), quienes reportaron un Índice de Validez de Contenido de 0,903 y un alfa de Cronbach de 0,883 para un cuestionario de 30 ítems Likert aplicado a 252 estudiantes de medicina. La consistencia interna demostrada (α global = 0,937; IC 95%: 0,872–0,963; α por dimensión: 0,823–0,947) supera los umbrales

convencionales de aceptabilidad y se ubica en el rango de «buena a excelente» según los criterios de George y Mallery (George & Mallery, 1999). Es relevante señalar que la literatura especializada en tamaño de muestra para pruebas de confiabilidad establece que, para estimar el alfa de Cronbach con un nivel de potencia del 80% y un error tipo I del 5%, se requieren entre 10 y 30 observaciones para instrumentos con correlaciones inter-ítem moderadas (Bujang et al., 2024), por lo que $n = 23$ es metodológicamente adecuado para esta fase piloto.

Los valores reducidos del W de Kendall, comprendidos entre 0,167 y 0,222, con valores de p superiores a 0,05, deben interpretarse considerando la distribución de las puntuaciones otorgadas por los expertos. Bujang et al. (2024) señalan que el coeficiente W de Kendall es sensible al rango de variación de las respuestas. Cuando los evaluadores concentran sus valoraciones en los niveles superiores de una escala, como ocurrió en el presente estudio, en el que la mayoría asignó la puntuación máxima de 4 en casi todos los criterios, disminuye la variabilidad de los rangos necesaria para detectar concordancia ordinal. Este fenómeno, denominado efecto techo, no implica por sí mismo que el instrumento carezca de validez. Ante esta limitada variabilidad, la V de Aiken constituye una medida complementaria apropiada para estimar el grado de acuerdo entre los jueces. En el presente estudio, este coeficiente alcanzó valores sistemáticamente elevados, lo que respalda la validez de contenido de los ítems evaluados (Penfield y Giacobbi, 2004). Asimismo, Calzolari (2023) ha documentado que una V de Aiken elevada puede coexistir con un W de Kendall reducido cuando existe una alta concentración de las respuestas en los valores superiores de la escala. Por tanto, ambos

indicadores deben interpretarse conjuntamente y en función de la distribución de las puntuaciones. El diseño mixto permitió identificar aspectos que no podían ser examinados únicamente mediante los ítems cerrados de la escala tipo Likert. El análisis temático de las respuestas obtenidas en las cuatro preguntas abiertas, realizado de acuerdo con el procedimiento propuesto por Braun y Clarke (2006), reveló que la elevada disposición registrada en la dimensión E estuvo condicionada por una premisa que no aparecía explícitamente en los ítems cerrados: la inteligencia artificial (IA) debe emplearse como una herramienta complementaria y no como sustituta del juicio clínico, además de operar bajo supervisión médica permanente.

Este resultado coincide con lo reportado por Hantel et al. (2024) en una encuesta aplicada a 204 oncólogos estadounidenses. En ese estudio, el 81,4 % de los participantes consideró necesario que los pacientes otorgaran su consentimiento para el uso de IA en las decisiones terapéuticas, mientras que el 84,8 % señaló que las recomendaciones generadas por estas tecnologías debían poder ser explicadas por el médico. La preocupación por la responsabilidad legal ante los errores algorítmicos, identificada en diversas respuestas del presente análisis temático, también ha sido señalada como una barrera ética relevante en oncología. Menos de la mitad de los oncólogos encuestados por Hantel et al. (2024) identificó con claridad al profesional médico como responsable de los posibles errores derivados del uso de IA.

La preocupación por la posible deshumanización de la relación médico-paciente, expresada con especial intensidad en el contexto oncológico “Son seres humanos, no números” (M021) y “Falta de acercamiento con

el paciente oncológico en la consulta” (M023)—, es consistente con la literatura sobre bioética clínica. Kelkar et al. (2024) sostienen que la IA dirigida directamente al paciente, a diferencia de aquella utilizada como apoyo para el profesional clínico, puede representar mayores amenazas para la dignidad del paciente oncológico debido a la posible erosión del vínculo terapéutico.

De manera similar, Gibelli et al. (2024) identifican la despersonalización de la atención y la opacidad de los algoritmos, conocida como el problema de la “caja negra”, entre los principales desafíos deontológicos asociados con la incorporación de IA en la medicina. Estas preocupaciones adquieren particular relevancia en especialidades caracterizadas por una elevada carga emocional, como la oncología. Por su parte, Welch et al. (2024) enfatizan que la conservación de interacciones empáticas continúa siendo esencial para el bienestar de los pacientes, incluso en contextos clínicos donde la IA se integra progresivamente en la atención sanitaria. Las preocupaciones relacionadas con la privacidad, el tratamiento de datos sensibles y la ausencia de una normativa regulatoria específica, identificadas como el tercer eje temático de la pregunta F4, reflejan una brecha relevante en el contexto ecuatoriano. Olayiwola et al. (2026), en una revisión narrativa sobre las barreras para la salud digital en países de ingresos bajos y medios, identificaron la insuficiencia de las normas de protección de datos y la debilidad de los mecanismos de ciberseguridad como obstáculos éticos importantes para la implementación de IA en el ámbito hospitalario.

Aunque Ecuador cuenta desde 2021 con la Ley Orgánica de Protección de Datos Personales, su aplicación específica en los servicios hospitalarios y en los sistemas basados en IA

todavía representa un desafío. En consecuencia, las preocupaciones expresadas por los participantes no deben interpretarse únicamente como resistencia al cambio tecnológico, sino como señales de alerta relacionadas con la protección de la información clínica, la seguridad de los sistemas y la responsabilidad institucional. La divergencia cualitativo-cuantitativa más significativa se identificó en la dimensión Barreras. Mientras que los ítems de la escala Likert presentaron puntuaciones altas y homogéneas, el análisis temático de las respuestas a la pregunta F2 mostró que los participantes percibían las barreras como problemas estructurales y sistémicos, y no como limitaciones atribuibles exclusivamente al individuo. Kaboré et al. (2022), en una revisión sistemática sobre la sostenibilidad de las intervenciones digitales en salud, señalan que la limitada conectividad a internet, la insuficiencia de equipos tecnológicos y los problemas de usabilidad de los sistemas son algunas de las barreras más frecuentes en los hospitales de países en desarrollo.

Los mismos autores sostienen que la resolución de estos obstáculos requiere intervenciones en los niveles político, administrativo e institucional, y no solamente procesos de capacitación dirigidos al personal sanitario. Este planteamiento coincide con las respuestas proporcionadas por los participantes del HECAM en la pregunta F2, quienes atribuyeron las dificultades para incorporar IA a las condiciones tecnológicas y organizacionales del establecimiento de salud. Los resultados presentan implicaciones concretas en tres niveles interdependientes: formación médica, gestión institucional y política sanitaria. En cuanto a la formación médica, el bajo resultado registrado en la dimensión B, particularmente en el ítem B8 ($M = 2,57$), sugiere que las competencias relacionadas con la IA todavía no

se han incorporado sistemáticamente en los programas de formación oncológica del HECAM. Park et al. (2024) concluyeron que, ante la ausencia de un consenso sobre la manera de integrar la IA en los currículos médicos, las instituciones que implementaron módulos formativos piloto obtuvieron mejoras en la alfabetización digital sin incrementar significativamente la carga académica percibida.

Por otra parte, la elevada puntuación obtenida en el ítem E23 ($M = 4,13$) evidencia una disposición favorable del personal para participar en procesos de capacitación sobre IA. Esta receptividad constituye una condición relevante para el éxito de las intervenciones formativas, especialmente cuando los programas se adaptan a las funciones, necesidades y experiencias previas de los profesionales de la salud (Blanco et al., 2025). En el nivel de gestión institucional, la correlación positiva entre las dimensiones Barreras y Expectativas ($\rho = 0,597$; $p = 0,003$) indica que el reconocimiento de los obstáculos existentes no necesariamente disminuye la disposición para adoptar estas tecnologías. Por el contrario, este resultado sugiere que el personal no rechaza la IA en sí misma, sino las condiciones actuales bajo las cuales podría implementarse. Zhou et al. (2026) señalan que las actitudes favorables hacia la IA como herramienta de apoyo aumentan cuando los profesionales consideran que su incorporación reducirá la carga asistencial en lugar de incrementarla.

Este resultado también se reflejó en las respuestas cualitativas del presente estudio. Algunos participantes condicionaron explícitamente la adopción de la IA a que su implementación no generara trabajo adicional. Por ejemplo, el participante M010 manifestó la

necesidad de “que se otorgue tiempo de la práctica asistencial para incorporar IA” (F3). En consecuencia, el diseño institucional debería priorizar la integración de estas herramientas en los flujos de trabajo existentes y evitar que su utilización se convierta en una carga operativa adicional. Yew et al. (2025), en una revisión sobre la implementación de tecnologías digitales en hospitales de países de ingresos medios, concluyen que el soporte técnico continuo, la disponibilidad de infraestructura y la adaptación de las herramientas al contexto local son factores determinantes para la sostenibilidad de la adopción.

Estos factores pueden resultar incluso más relevantes que las características técnicas del sistema implementado. En el nivel de política sanitaria, la preocupación reiterada por la ausencia de una normativa regulatoria específica, identificada en las respuestas de la pregunta F4, evidencia una brecha que no puede ser resuelta únicamente mediante acciones formativas o administrativas dentro del hospital. Barbosa y Goldfajn (2026), en el marco de las orientaciones promovidas por la Organización Panamericana de la Salud, señalan que la regulación de la IA en salud debe garantizar la supervisión humana, la transparencia algorítmica y la equidad en el acceso como condiciones previas para una implementación responsable. En América Latina, donde la infraestructura tecnológica continúa siendo uno de los principales obstáculos para la transformación digital de los sistemas sanitarios (Regazzoni, 2024), la política ecuatoriana de transformación digital debería traducir las preocupaciones expresadas por el personal médico en estándares específicos para la utilización de IA en oncología. Estos estándares deberían incluir protocolos de supervisión humana, responsabilidad profesional, protección de

datos, evaluación de riesgos y auditoría periódica de los sistemas algorítmicos. El muestreo no probabilístico por conveniencia y el reducido tamaño de la muestra ($n = 23$) constituyen las principales limitaciones de la investigación. Bujang et al. (2024) señalan que una muestra de entre 20 y 30 participantes puede ser útil en estudios piloto orientados a obtener estimaciones preliminares de confiabilidad; sin embargo, este tamaño resulta insuficiente para realizar análisis factoriales confirmatorios o generalizar los resultados a poblaciones más amplias.

Los tamaños del efecto, entre moderados y grandes, identificados en las comparaciones por categoría profesional ($\eta^2 = 0,175\text{--}0,199$) deben interpretarse con cautela debido a la limitada potencia estadística de las pruebas no paramétricas y al reducido número de participantes en algunos subgrupos. En particular, la categoría “Otro” estuvo conformada por dos participantes, al igual que el grupo con entre uno y tres años de experiencia profesional. Estas condiciones incrementan el riesgo de cometer un error de tipo II, es decir, de no detectar diferencias que podrían existir realmente entre los grupos. Giebel et al. (2026) advierten que, en investigaciones realizadas en contextos institucionales homogéneos, la similitud de las experiencias y condiciones laborales de los participantes puede reducir la variabilidad de las respuestas y limitar la capacidad para identificar diferencias entre subgrupos.

En el presente estudio, el hecho de que todos los participantes pertenecieran al mismo hospital de referencia pudo haber reducido la dispersión de las puntuaciones y favorecido la obtención de resultados no significativos. Otro aspecto que debe considerarse es el posible sesgo de deseabilidad social, frecuente en

investigaciones sobre tecnologías emergentes que generan elevadas expectativas académicas y profesionales. Vecellio (2025), en una encuesta realizada con médicos de atención primaria en Suiza, señaló que las intenciones declaradas de utilizar IA suelen ser más favorables que su utilización real posterior. Esto sugiere que los estudios de percepción pueden sobreestimar la disposición efectiva de los profesionales para adoptar estas tecnologías.

Asimismo, el diseño transversal permitió obtener una representación de las percepciones del personal en un momento específico, pero no hizo posible analizar la evolución de sus actitudes después de adquirir experiencia directa con herramientas de IA. Una revisión sistemática con metaanálisis sobre el conocimiento, las actitudes y las prácticas de los médicos frente a la IA clínica encontró que el nivel de utilización real suele ser inferior al nivel de aceptación declarado. Por tanto, una actitud favorable no garantiza necesariamente la adopción efectiva de estas tecnologías (Abdulazeem et al., 2025). El alcance de la investigación, restringido a un único hospital de tercer nivel de la ciudad de Quito, también limita la transferibilidad de los resultados. El HECAM dispone de una dotación de recursos y de una capacidad técnica que pueden ser superiores a las de otros establecimientos del sistema público ecuatoriano. Por esta razón, las barreras estructurales identificadas podrían manifestarse con mayor intensidad en hospitales de menor complejidad o ubicados en zonas con conectividad e infraestructura tecnológica más limitadas.

Los resultados de esta prueba piloto permiten plantear tres líneas prioritarias para futuras investigaciones. La primera corresponde a la validación confirmatoria del Cuestionario V1.0 mediante una muestra ampliada y multicéntrica.

Un tamaño muestral igual o superior a 100 participantes podría facilitar la evaluación de la estructura de cuatro dimensiones propuesta, aunque su suficiencia deberá determinarse en función del número de ítems, las cargas factoriales y el modelo estadístico seleccionado.

La versión V2.0 del instrumento debería incorporar ítems relacionados con la normativa regulatoria, la protección de datos y los marcos de responsabilidad profesional aplicables al uso de IA. Estas dimensiones fueron identificadas como ausentes mediante el análisis temático. También debería considerarse la recodificación o inversión de los ítems de la dimensión Barreras antes de calcular las puntuaciones globales, debido a que los reactivos formulados en sentido negativo requieren un tratamiento coherente para evitar interpretaciones erróneas (Taber, 2018). Jerez et al. (2025) señalan que la adaptación de los instrumentos de percepción de IA a los contextos culturales e institucionales específicos puede mejorar su capacidad para predecir la aceptación y utilización de estas tecnologías.

Por consiguiente, la validación del cuestionario debería considerar las particularidades del sistema sanitario ecuatoriano, la disponibilidad tecnológica de los hospitales y las experiencias previas del personal con sistemas digitales. La segunda línea de investigación corresponde al desarrollo de estudios longitudinales que permitan examinar la evolución de las actitudes médicas desde la expectativa inicial hasta la experiencia real de utilización. Wang et al. (2024), en una revisión sistemática con metaanálisis, identificaron que la mayoría de las investigaciones sobre adopción de tecnologías en salud emplea diseños transversales. Esta característica impide establecer si las actitudes favorables anteceden a la experiencia de uso o se desarrollan como resultado de ella. En el

contexto oncológico ecuatoriano, un diseño de pretest y posttest que evalúe las actitudes antes y después de un programa piloto de capacitación y utilización de IA proporcionaría información más sólida que una nueva encuesta transversal. Este diseño permitiría examinar cambios en el conocimiento, la percepción de utilidad, la confianza, las preocupaciones éticas y la intención de uso después de una experiencia práctica supervisada. La tercera línea, y la de mayor urgencia desde la perspectiva clínica, corresponde al desarrollo de estudios de implementación que evalúen el efecto de la IA sobre resultados concretos relacionados con el cáncer de mama en Ecuador. Entre estos indicadores podrían incluirse el tiempo transcurrido entre la consulta inicial y el diagnóstico histopatológico, la concordancia en la estadificación, la oportunidad del inicio del tratamiento y la supervivencia a cinco años.

D'Amiano et al. (2025) sostienen que la transparencia y la representación adecuada de las poblaciones constituyen condiciones esenciales para garantizar la generalización de los resultados de las investigaciones oncológicas basadas en IA. Los modelos entrenados con datos procedentes de poblaciones diferentes pueden reproducir sesgos existentes y ampliar las desigualdades sanitarias en lugar de reducirlas. En ausencia de evidencia clínica generada en el contexto nacional, la inversión en IA oncológica podría continuar percibiéndose como una importación tecnológica sin suficiente apropiación institucional ni garantía de sostenibilidad.

Conclusiones

Esta prueba piloto alcanzó sus tres objetivos específicos: validar psicométricamente el instrumento de medición, caracterizar la percepción del personal médico del HECAM sobre la IA en oncología y explorar los factores

que condicionan su disposición a adoptarla. Las conclusiones se presentan en correspondencia con los hallazgos del estudio: El Cuestionario V1.0 demostró validez de contenido alta (V de Aiken global = 0,924; IC 95%: 0,692–1,000), consistencia interna excelente (α de Cronbach global = 0,937; IC 95%: 0,872–0,963) y valores de suficiencia adecuados en cuatro de cinco dimensiones, posicionándolo como un instrumento psicométricamente sólido para aplicaciones ampliadas. Los resultados del W de Kendall ($W = 0,167$ – $0,222$; $p > 0,05$), aunque bajos, se explican por el efecto techo de las puntuaciones y no reflejan desacuerdo sustantivo entre los expertos evaluadores.

El nivel de conocimiento sobre IA fue la dimensión con menor puntaje ($M = 15,8/25$; $DE = 4,4$), con el ítem referido a capacitación formal (B8, $M = 2,57$) como el más bajo del instrumento. La brecha formativa es real y demanda intervención curricular específica en los programas de educación continua del HECAM. La percepción de utilidad y confianza se situó en un rango moderado ($M = 16,6/25$), con reservas específicas respecto a la confianza en los resultados de la IA (C14, $M = 2,96$) y a su capacidad para reducir errores clínicos (C15, $M = 3,00$). Estas reservas reflejan una evaluación técnicamente fundamentada, no un rechazo a la tecnología, y son convergentes con lo reportado en estudios internacionales con oncólogos. Las barreras percibidas fueron altas y estadísticamente homogéneas en toda la muestra ($M = 19,1/25$), sin diferencias significativas por sexo, profesión ni años de experiencia. La ausencia de correlación entre Conocimiento y Barreras ($\rho = 0,079$; $p = 0,722$) confirma que los obstáculos son estructurales, infraestructura, conectividad, tiempo y no atribuibles al déficit formativo individual. La disposición a adoptar IA fue la dimensión con mayor puntaje ($M = 19,3/25$; E23, $M = 4,13$),

con una correlación muy fuerte con Utilidad y confianza ($\rho = 0,894$; $p < 0,001$), consistente con el Modelo de Aceptación Tecnológica. El análisis temático cualitativo precisa que esta predisposición es condicionada: el personal médico acepta la IA únicamente como herramienta complementaria al juicio clínico, bajo supervisión médica permanente, con evidencia clínica verificable y en un marco normativo que defina responsabilidades ante errores algorítmicos. Las correlaciones entre dimensiones identificaron que el par Utilidad-Expectativas ($\rho = 0,894$) es el eje central del modelo de aceptación en esta muestra. La única correlación no significativa, conocimiento con Barreras ($\rho = 0,079$), implica que las intervenciones de capacitación y las de mejora de infraestructura deben diseñarse y ejecutarse en paralelo, no en secuencia. En conjunto, los resultados refutan la hipótesis simplificadora de que mayor conocimiento conduce automáticamente a menor percepción de barreras. El personal médico del HECAM muestra predisposición genuina hacia la IA en oncología, pero la condiciona a tres requisitos que deben concurrir simultáneamente: capacitación acreditada, infraestructura tecnológica funcional y un marco regulatorio que garantice la supervisión humana del proceso diagnóstico y delimite la responsabilidad profesional ante los errores del algoritmo. El Cuestionario V1.0 validado en este estudio ofrece una herramienta replicable para medir estas percepciones en estudios multicéntricos y longitudinales que permitan evaluar el impacto de intervenciones específicas sobre la adopción de IA en la oncología ecuatoriana.

Agradecimientos

Los autores agradecen a la Dirección de Investigación y Desarrollo (DIDE) de la Universidad Técnica de Ambato (UTA). Este

estudio fue desarrollado en el marco del Proyecto de Investigación PFCS59, aprobado por la Dirección de Investigación y Desarrollo (DIDE) de la Universidad Técnica de Ambato (UTA) mediante resolución UTA-CONIN-2025-0060-R. Los autores no recibieron financiamiento externo adicional para la realización de este trabajo.

Referencias Bibliográficas

- Abdulazeem, H. M., Meckawy, R., Schwarz, S., Novillo-Ortiz, D., & Klug, S. J. (2025). Knowledge, attitude, and practice of primary care physicians toward clinical AI-assisted digital health technologies: Systematic review and meta-analysis. *International Journal of Medical Informatics*, 201, 105945.
<https://pubmed.ncbi.nlm.nih.gov/40286705/>
- Aiken, L. R. (1985). Three coefficients for analyzing the reliability and validity of ratings. *Educational and Psychological Measurement*, 45(1), 131–142.
https://www.safeandcivilschools.com/Schoolwide?gad_source=1&gad_campaignid=215
- American Medical Association. (2026). *Physician survey on augmented intelligence*. AMA.
<https://www.reportlinker.com/market->
- Barbosa, J., & Goldfajn, I. (2026). *Inteligencia artificial en salud pública*.
<https://www.paho.org/sites/default/files/2026/05/ai-ra-tool-rev-final-esp-aug-1.pdf>
- Blanco, M. A., Nelson, S. W., Ramesh, S., Callahan, C. E., Josephs, K. A., Jacque, B., & Baecher-Lind, L. E. (2025). Integrating artificial intelligence into medical education: A roadmap informed by a survey of faculty and students. *Medical Education Online*, 30(1), 2531177.
<https://pubmed.ncbi.nlm.nih.gov/40660466/>
- Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77–101.
<https://www.tandfonline.com/doi/abs/10.1191/1478088706qp063oa>

- Bujang, M, Omar, E, Foo, D. & Hon, Y. K. (2024). Sample size determination for conducting a pilot study to assess reliability of a questionnaire. *Restorative Dentistry & Endodontics*, 49(1).
<https://pubmed.ncbi.nlm.nih.gov/38449496/>
- Calzolari, A. (2023). Aspectos prácticos del uso del coeficiente de concordancia *W* de Kendall para el jueceo de cuestionarios en enfermería. *Arandu Poty*, 2(2), 23–32.
<https://divulgacioncientifica.unca.edu.py/index.php/AranduPoty/article/view/61>
- Cascella, M., Guerra, C., De Feo, R., Cerrone, V., Farah, S., Sarzi-Puttini, P., & Salaffi, F. (2024). Cross-sectional study on medical attitude towards artificial intelligence use in fibromyalgia: Insights from the Annual Thinking Lab on Fibromyalgia Syndrome (ATLAS 2024). *Translational Medicine@UniSa*, 26(2), 153.
<https://pmc.ncbi.nlm.nih.gov/articles/PMC11960775/>
- Cazap, E., & de Celis, E. S. P. (2024). Announcing the new editor-in-chief of *ecancermedicalsecience*. *Ecancermedicalsecience*, 18.
<https://doi.org/10.3332/ecancer.2024.ed133>
- Colegio de Médicos de Pichincha. (2026). *En Ecuador, el cáncer de mama es el de mayor incidencia y mortalidad en mujeres*.
<https://colegiomedicodepichincha.org/en-ecuador-el-cancer-de-mama-es-el-de-mayor-incidencia-y-mortalidad-en-mujeres/>
- D’Amiano, A. J., Cheunkarndee, T., Azoba, C., Chen, K. Y., Mak, R. H., & Perni, S. (2025). Transparency and representation in clinical research utilizing artificial intelligence in oncology: A scoping review. *Cancer Medicine*, 14(5), e70728.
<https://pubmed.ncbi.nlm.nih.gov/40059400/>
- Dean, T. B., Seecheran, R., Badgett, R. G., Zackula, R., & Symons, J. (2024). Perceptions and attitudes toward artificial intelligence among frontline physicians and physicians’ assistants in Kansas: A cross-sectional survey. *JAMIA Open*, 7(4), ooae100.
<https://pubmed.ncbi.nlm.nih.gov/40059400/>
- Eltawil, F. A., Atalla, M., Boulos, E., Amirabadi, A., & Tyrrell, P. N. (2023). Analyzing barriers and enablers for the acceptance of artificial intelligence innovations into radiology practice: A scoping review. *Tomography*, 9(4), 1443–1455.
<https://pubmed.ncbi.nlm.nih.gov/40059400/>
- ESMO Daily Reporter. (s. f.). *La IA transforma el diagnóstico del cáncer: Persisten las barreras sistemáticas*. Recuperado el 10 de mayo de 2026, de
<https://dailyreporter.esmo.org/spotlight/ai-is-transforming-cancer-diagnosis-but-systemic-barriers-still-hold-it-back>
- George, D., & Mallery, P. (1999). *SPSS for Windows step by step: A simple guide and reference*. Allyn & Bacon.
<https://eric.ed.gov/?id=ED425201>
- Gibelli, F., Maio, G., & Ricci, G. (2024). Healthcare in the age of sapient machines: Physician decision-making autonomy faced with artificial intelligence. Ethical, deontological and compensatory aspects. *Frontiers in Medicine*, 11, 1477371.
<https://eric.ed.gov/?id=ED425201>
- Giebel, G. D., Raszke, P., Tokic, M., Palmowski, L., Timmesfeld, N., Nowak, H., Adamzik, M., Heinz, P., Brunkhorst, F. M., & Wasem, J. (2026). Attitude and perception toward artificial intelligence among German physicians with intensive care experience: A survey study. *Frontiers in Health Services*, 5, 1–10.
<https://doi.org/10.3389/frhs.2025.1721620>
- Guzmán, C. (2024). *Prevalencia de la aplicación de modelos y conocimientos en inteligencia artificial para el diagnóstico temprano de cáncer por médicos radiólogos de la ciudad de Quito en 2024*. Universidad de Las Américas.
<http://dspace.udla.edu.ec/handle/33000/17130>
- Hantel, A., Walsh, T. P., Marron, J. M., Kehl, K. L., Sharp, R., Van Allen, E., & Abel, G. A. (2024). Perspectives of oncologists on the ethical implications of using artificial intelligence for cancer care. *JAMA Network*

- Open*, 7(3), e244077.
<https://eric.ed.gov/?id=ED425201>
- Kaboré, S. S., Ngangue, P., Soubeiga, D., Barro, A., Pilabré, A. H., Bationo, N., Pafadnam, Y., Drabo, K. M., Hien, H., & Savadogo, G. B. L. (2022). Barriers and facilitators for the sustainability of digital health interventions in low- and middle-income countries: A systematic review. *Frontiers in Digital Health*, 4, 1014375. <https://eric.ed.gov/?id=ED425201>
- Kelkar, A. H., Hantel, A., Koranteng, E., Cutler, C. S., Hammer, M. J., & Abel, G. A. (2024). Digital health to patient-facing artificial intelligence: Ethical implications and threats to dignity for patients with cancer. *JCO Oncology Practice*, 20(3), 314–317. <https://eric.ed.gov/?id=ED425201>
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine*, 17(1), 195. <https://eric.ed.gov/?id=ED425201>
- Khan, M. A., Queen, A., Yousuf, M., Patel, Y. A., Kausar, M. A., Ali, A., Anwar, S., Khan, F. H., Elagib, H. M., Shahien, M. M., & Alshabrmī, F. M. (2026). The expanding role of artificial intelligence in personalised medicine: From innovation to individualized care. *Frontiers in Medicine*, 13, 1795879. <https://doi.org/10.3389/fmed.2026.1795879>
- Khojasteh, L., Karimian, Z., Nasiri, E., Kafipour, R., & Farahmandi, A. Y. (2025). Artificial intelligence and academic writing questionnaire (AI-AWQ): Development and validation among medical students' experiences using exploratory factor analysis. *BMC Medical Education*, 25(1), 1697. <https://pubmed.ncbi.nlm.nih.gov/41402961/>
- Mache, S., Bernburg, M., Würtenberger, A., & Groneberg, D. A. (2025). Artificial intelligence in primary care: Support or additional burden on physicians' healthcare work? A qualitative study. *Clinics and Practice*, 15(8), 138. <https://doi.org/10.3389/fmed.2026.1795879>
- Maldonado, I., Checa, F., Tarupi, W., Moreno, A., Noboa, A., Pacheco, L., Puente, R., Soria, T., & Cevallos, I. (2025). Cáncer en el Ecuador: ¿Qué ha cambiado en las últimas tres décadas? *Metro Ciencia*, 33(Suplemento 1), s56–s69. <https://doi.org/10.47464/metro-ciencia/vol33/suplemento-1/2025/s56-s69>
- Ministerio de Salud Pública del Ecuador. (2024). *Política nacional de transformación digital*. <https://www.salud.msp.gob.ec>
- Montero, K., & Silva, J. (2025). Uso de la inteligencia artificial en el diagnóstico de cáncer de mama. *Ciencia Latina Revista Científica Multidisciplinar*. <https://ciencialatina.org/index.php/cienciala/article/view/17982/25851>
- Narcisol, P., & Alcívar, R. (2026). Análisis comparativo de algoritmos basados en inteligencia artificial para la detección temprana del cáncer de mama. *Revista Científica de Informática ENCRIPtar*, 9(17), 65–86. <https://doi.org/10.56124/encriptar.v9i17.004>
- Olayiwola, Q. B., Sanusi, O. M., Amoo, G. S., Agboola, O. J., Adeyemi, J. A., Suleiman, H. A., Ibrahim, M. A., & Hassan, T. A. (2026). Barriers to digital health implementation in low- and middle-income countries: A narrative review. *Discover Public Health*, 23(1), 499.
- Organización Panamericana de la Salud. (2021). *Inteligencia artificial en salud pública*. <https://www.paho.org/es/documentos/inteligencia-artificial-salud-publica>
- Park, S. H., Pinto-Powell, R., Thesen, T., Lindqwister, A., Levy, J., Chacko, R., Gonzalez, D., Bridges, C., Schwendt, A., & Byrum, T. (2024). Preparing healthcare leaders of the digital age with an integrative artificial intelligence curriculum: A pilot study. *Medical Education Online*, 29(1), 2315684. <https://subscriptions.elsevier.com/clinicalkey-ai>
- Penfield, R. D., & Giacobbi, P. R., Jr. (2004). Applying a score confidence interval to Aiken's item content-relevance index. *Measurement in Physical Education and*

- Exercise Science*, 8(4), 213–225.
https://www.tandfonline.com/doi/abs/10.1207/s15327841mpee0804_3
- Qi, Y. (2026). The role of artificial intelligence applications in enhancing healthcare professionals' performance in the context of "Internet Plus Healthcare." *The Development of Humanities and Social Sciences*, 2(1), 87–100.
<https://doi.org/10.71204/vs0xng32>
- Radeva, M. N., Hristova, E., Georgiev, R. T., & Zlatarova, Z. I. (2026). Awareness, trust, and expectations of AI for glaucoma care among Bulgarian ophthalmologists: Role of demographic factors. *PLOS Digital Health*, 5(1), e0001199.
<https://journals.plos.org/digitalhealth/article?id=10.1371/journal.pdig.0001199>
- Ramírez, M., Alvarado, V., Villavicencio, F. P. R., Cárdenas, J. S., Padilla, A. T. O., & Rodríguez, G. A. (2024). Diagnóstico asistido por computadora en mamografías para la detección del cáncer de mama. *Revista de la Facultad de Medicina Humana*, 24(4), 20.
<https://dialnet.unirioja.es/servlet/articulo?codigo=9795270>
- Regazzoni, C. J. (2024, noviembre). *Health, Latin America, and the promise of artificial intelligence*. Think Global Health.
<https://www.thinkglobalhealth.org/article/health-latin-america-and-promise-artificial-intelligence>
- Salazar-Garcés, L. F., Morales-Urrutia, E., Cashabamba, F., Proaño Alulema, R. X., & Leiva Suero, L. E. (2026). Evaluating AI-driven precision oncology for breast cancer in low- and middle-income countries: A review of machine learning performance, genomic data use, and clinical feasibility. *Frontiers in Digital Health*, 7.
<https://doi.org/10.3389/fdgth.2025.1702339>
- SOLCA Núcleo Tungurahua. (2025). *SOLCA Núcleo Tungurahua*.
<https://solcatungurahua.org/>
- Taber, K. S. (2018). The use of Cronbach's alpha when developing and reporting research instruments in science education. *Research in Science Education*, 48(6), 1273–1296.
- Trujillo Ruiz, J. (2026). *Guía básica de inteligencia médica artificial*.
<https://doi.org/10.13039/501100011033/y>
- Vecellio, M. (2025). Physician readiness for AI in primary care: A cross-sectional survey on the knowledge-attitude gap and implementation priorities in Switzerland. *medRxiv*.
- Villacrés, T., Soria, T., Buizza, C., & González-Andrade, F. (2018). Se requieren más médicos especialistas para tratar el cáncer: Urge la formación prioritaria y un número suficiente de oncólogos en Ecuador. *Revista de la Facultad de Ciencias Médicas de Quito*, 43(2).
<https://biblioteca.solcaquito.org.ec/entities/publication/c157c8a5-2601-4851-9b8e-4558ae13d843>
- Wang, M., Huang, K., Li, X., Zhao, X., Downey, L., Hassounah, S., Liu, X., Jin, Y., & Ren, M. (2024). Health workers' adoption of digital health technology in low- and middle-income countries: A systematic review and meta-analysis. *Bulletin of the World Health Organization*, 103(2), 126.
<https://trinetx.com/data/?campaignid=23910>
- Weidener, L., & Fischer, M. (2024). Artificial intelligence in medicine: Cross-sectional study among medical students on application, education, and ethical aspects. *JMIR Medical Education*, 10(1), e51247.
<https://pubmed.ncbi.nlm.nih.gov/38180787/>
- Welch, J., Bashir, H., Leach, E., & Wells, M. (2024). Navigating the impact of artificial intelligence on humanistic medicine. *International Journal of Computing and Artificial Intelligence*, 5(1), 59–60.
<https://www.computersciencejournals.com/ijcai/article/85/5-1-16-148.pdf>
- Yáñez, O., Kim, J., Bonilla, J., Montalvo, F., & Veas Romero, M. (2025). Perspectivas estudiantiles y docentes sobre la IA en la educación sanitaria: Revisión sistemática exploratoria. *Revista Española de Educación Médica*, 6(2), 176–197.
<https://dialnet.unirioja.es/servlet/articulo?codigo=10410543>

Yew, S. Q., Trivedi, D., Adanan, N. I. H., & Chew, B. H. (2025). Facilitators and barriers to the implementation of digital health technologies inhospital settings in lower- and middle-income countries since the onset of the COVID-19 pandemic: Scoping review. *Journal of Medical Internet Research*, 27, e63482. <https://pubmed.ncbi.nlm.nih.gov/40053793/>

Zanardo, M., Visser, J. J., Colarieti, A., Cuocolo, R., Klontzas, M. E., Pinto dos Santos, D., Sardanelli, F., & European Society of Radiology. (2024). Impact of AI on radiology: A EuroAIM/EuSoMII 2024 survey among members of the European Society of Radiology. *Insights into Imaging*,

15(1), 240. <https://pubmed.ncbi.nlm.nih.gov/39373853/>
Zhou, X., Jomhari, N., Farid, N. D. N., & Xing, Y. (2026). Physicians' perceptions and attitudes on artificial intelligence in hospital management: A qualitative study. *BMC Health Services Research*, 26(1), 14. <https://link.springer.com/article/10.1186/s12913-025-13815-1>



Esta obra está bajo una licencia de **Creative Commons Reconocimiento-No Comercial 4.0 Internacional**. Copyright © Fanny Michelle Meléndez Yáñez, Luis Fabián Salazar Garcés

Declaraciones éticas y editoriales del artículo

Contribución de los autores (Taxonomía CRediT)

Fanny Michelle Meléndez-Yáñez: Redacción del borrador original del manuscrito; recolección de datos e investigación de campo en el HECAM; curación y análisis formal de los datos; revisión y edición del manuscrito.
Luis Fabián Salazar-Garcés: Conceptualización e idea original del estudio; diseño metodológico; análisis formal de los datos; revisión crítica y correcciones del manuscrito; supervisión y dirección del proyecto de investigación.

Declaración de conflicto de intereses

Los autores declaran no tener ningún conflicto de interés económico, profesional o personal que pudiera haber influido en el diseño, la ejecución, el análisis o la publicación de este estudio.

Declaración de financiamiento

La presente investigación no recibió financiamiento específico de agencias públicas, comerciales o de organizaciones sin fines de lucro. En caso de existir financiamiento institucional o externo, este deberá ser declarado explícitamente por los autores en esta sección.

Declaración del editor

El editor responsable certifica que el proceso editorial del presente artículo se desarrolló conforme a los principios de integridad científica, transparencia y buenas prácticas editoriales. El manuscrito fue sometido a un proceso de evaluación mediante revisión por pares doble ciego, garantizando la confidencialidad de la identidad de los autores y revisores durante todo el proceso de dictamen académico. Asimismo, el editor declara que el artículo cumple con los criterios científicos, metodológicos y éticos establecidos por la revista.

Declaración de los revisores

Los revisores externos que participaron en la evaluación del presente manuscrito declaran haber realizado el proceso de revisión de manera objetiva, independiente y confidencial. Asimismo, manifiestan que no mantienen conflictos de interés con los autores ni con la investigación evaluada, y que sus observaciones y recomendaciones se fundamentan exclusivamente en criterios científicos, metodológicos y académicos.

Declaración ética de la investigación

Los autores declaran que la investigación se desarrolló respetando los principios éticos de la investigación científica, garantizando la confidencialidad de los datos y el respeto a los participantes del estudio. En los casos en que la investigación involucre seres humanos, los procedimientos deben ajustarse a los principios éticos establecidos en la Declaración de Helsinki y a las normativas institucionales correspondientes.

Declaración sobre el uso de inteligencia artificial

Los autores declaran que el uso de herramientas de inteligencia artificial, en caso de haberse utilizado durante el proceso de investigación o redacción del manuscrito, se realizó únicamente como apoyo técnico para mejorar la claridad del lenguaje o el análisis de información, manteniendo siempre la responsabilidad intelectual sobre el contenido del artículo. Las herramientas de inteligencia artificial no fueron utilizadas como autoras del manuscrito ni sustituyen la responsabilidad académica de los investigadores.

Disponibilidad de datos

Los datos que respaldan los hallazgos de este estudio están disponibles previa solicitud razonada al autor de correspondencia, sujeto a las restricciones éticas aplicables en virtud del consentimiento informado otorgado por los participantes y la aprobación del CEISH-UTA.

