



Inteligencia artificial en la verificación de la calidad de dispositivos electrónicos para Bachillerato Técnico en Electrónica

**Artificial intelligence in the quality verification of electronic devices for technical
high school electronics education**

**Artículo de investigación científica
Ciencias de la Educación**

Ximena Alexandra Arcos -Tovar. ^I

ximena.arcos@educacion.gob.ec.

 <https://orcid.org/0009-0002-4344-5846>

Unidad Educativa Ramón Barba Naranjo
Cotopaxi, Ecuador

Fecha de envío: 2026-05-08

Fecha de revisión: 2026-06-07

Fecha da aceptación: 2026-07-07

Resumen

El objetivo del estudio fue analizar el efecto de la estrategia didáctica AI-QElectro RA, basada en inteligencia artificial (IA), visión computacional, realidad aumentada (RA) y retroalimentación guiada, en el desarrollo de destrezas para verificar la calidad de dispositivos electrónicos en estudiantes de Bachillerato Técnico en Electrónica. La metodología se planteó desde un diseño cuasi experimental de enfoque correlacional-descriptivo, con grupo de control y grupo experimental, conformado por 80 participantes distribuidos en dos grupos de 40. Se elaboró un test de base estructurada para valorar destrezas de inspección visual, lectura de parámetros eléctricos, detección de fallas, registro técnico y toma de decisiones de calidad; el contenido fue validado por diez expertos y alcanzó una confiabilidad Alfa de Cronbach de 0.89, valor interpretado como muy confiable para fines educativos. Los resultados referenciales evidenciaron que el grupo experimental obtuvo un mayor incremento promedio en el postest, especialmente en identificación de defectos, trazabilidad de mediciones y diagnóstico de continuidad, con diferencias estadísticamente significativas frente al grupo de control. La prueba t de Student mostró una diferencia favorable al grupo experimental, mientras que el tamaño del efecto d de Cohen fue alto en las destrezas centrales de verificación electrónica. Se concluye que la incorporación pedagógica de IA y RA puede fortalecer aprendizajes técnicos situados, siempre que se acompañe de criterios éticos, guía docente, evaluación práctica y vinculación con estándares de calidad propios del campo electrónico.

Palabras clave: inteligencia artificial; verificación de calidad; dispositivos electrónicos; Bachillerato Técnico; realidad aumentada.

Abstract

The objective of this study was to analyze the effect of the AI-QElectro RA didactic strategy, based on artificial intelligence (AI), computer vision, augmented reality (AR), and guided feedback, on the development of skills for verifying the quality of electronic devices among students in technical high school electronics education. The methodology followed a quasi-experimental design with a descriptive-correlational approach, including a control group and an experimental group, with 80 participants distributed into two groups of 40. A structured test was developed to assess skills related to visual inspection, interpretation of electrical parameters, fault detection, technical recording, and quality decision-making. The content was validated by ten experts and achieved a Cronbach's alpha reliability coefficient of 0.89, interpreted as highly reliable for

educational purposes. The referential results showed that the experimental group obtained a higher average increase in the post-test, especially in defect identification, measurement traceability, and continuity diagnosis, with statistically significant differences compared with the control group. Student's t-test showed a favorable difference for the experimental group, while Cohen's d indicated a high effect size in the core electronic verification skills. It is concluded that the pedagogical integration of AI and AR can strengthen situated technical learning when accompanied by ethical criteria, teacher guidance, practical assessment, and links to quality standards in electronics.

Keywords: artificial intelligence; quality verification; electronic devices; technical high school; augmented reality.

Introducción

La incorporación de inteligencia artificial en la educación técnica ya no puede abordarse como una tendencia lejana, sino como una condición formativa vinculada con los cambios del trabajo, la producción y la vida cotidiana. En el área electrónica, verificar la calidad de un dispositivo exige interpretar evidencias visuales, eléctricas y funcionales; por ello, el estudiante no solo requiere memorizar componentes, sino reconocer defectos, contrastar mediciones, tomar decisiones y registrar información técnica con precisión. La literatura reciente sobre IA en educación sostiene que los sistemas adaptativos, los tutores inteligentes, la analítica de aprendizaje y la evaluación apoyada por algoritmos pueden mejorar la personalización, la retroalimentación y la identificación de necesidades de aprendizaje, aunque también advierte riesgos de dependencia tecnológica, sesgos y uso superficial de las herramientas (Alfarwan, 2025; Garzón, 2025; Lee et al., 2024; Wang et al., 2024; Weng et al., 2024; Zhao et al., 2024). Desde esta mirada, el problema no consiste en usar IA por novedad, sino en integrarla con una intención didáctica clara y con actividades verificables en taller.

En el ámbito industrial, la verificación de calidad de productos electrónicos se ha transformado por la convergencia entre visión computacional, sensores, aprendizaje profundo, modelos predictivos y sistemas de inspección automatizada. Saadallah et al. (2022) demostraron que los modelos de aprendizaje profundo pueden predecir la calidad de placas de circuito impreso a partir de campos de visión y explicaciones visuales, lo cual es especialmente pertinente para enseñar al estudiante a relacionar datos, imágenes y decisiones técnicas. Sundaram y Zeid (2023) sistematizaron soluciones de inspección inteligente para manufactura y destacaron que la IA permite reducir errores humanos en

tareas repetitivas, identificar defectos y mejorar la consistencia de los criterios de calidad. De forma complementaria, Ni et al. (2024), Rydzi et al. (2024), Corallo et al. (2024) y Trampert et al. (2025) han mostrado que los enfoques de inspección visual inteligente, aprendizaje semisupervisado y analítica predictiva son relevantes cuando hay pocas etiquetas disponibles, procesos dinámicos y necesidad de transferir conocimiento entre contextos productivos.

La educación técnico-profesional requiere traducir estos avances a experiencias de aula y laboratorio. El Ministerio de Educación, Deporte y Cultura del Ecuador plantea que el Bachillerato Técnico ofrece formación complementaria en áreas técnicas, artísticas o deportivas orientada a los intereses, capacidades y habilidades del estudiantado, y dentro del área técnica industrial se reconoce la figura profesional de Electrónica de Consumo. Esta orientación exige que la enseñanza no se limite a conceptos abstractos, sino que conecte con problemas reales de diagnóstico, mantenimiento, medición y control de calidad. En esa misma dirección, las orientaciones nacionales sobre uso pedagógico de herramientas de inteligencia artificial recomiendan integrar estas tecnologías de manera efectiva y ética en el proceso de enseñanza-aprendizaje, lo que supone acompañamiento docente, criterios de evaluación claros y protección del aprendizaje humano frente al uso mecánico de respuestas generadas (Ministerio de Educación, Deporte y Cultura, 2024, 2026).

En América Latina, la Comisión Económica para América Latina y el Caribe (CEPAL) ha sostenido que la transformación digital y la IA pueden impulsar productividad, innovación y capacidades digitales, pero también ha señalado brechas de infraestructura, formación y gobernanza que condicionan el aprovechamiento educativo y productivo de estas tecnologías (CEPAL, 2025, 2026). La Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO) insiste en que la IA debe orientarse por una visión centrada en el ser humano, con políticas que protejan equidad, inclusión, transparencia, privacidad y calidad educativa (UNESCO, 2023, 2024). Por tanto, la integración de IA en Bachillerato Técnico no puede interpretarse como sustitución del docente ni del razonamiento técnico del estudiante; más bien, debe funcionar como mediación didáctica para observar mejor, explicar con mayor precisión, practicar de forma segura y argumentar decisiones de calidad.

La realidad aumentada también ha sido reconocida como recurso prometedor para la formación técnica, porque permite superponer instrucciones, alertas, rutas de

procedimiento o modelos tridimensionales sobre objetos reales. Bacca et al. (2018, 2019) demostraron que el diseño motivacional de aplicaciones de RA puede fortalecer la participación y la comprensión en educación vocacional. Sirakaya y Çakmak (2018) hallaron efectos positivos de la RA sobre el logro y la autoeficacia en formación vocacional, mientras que Candido et al. (2023) evidenciaron que docentes y formadores valoran la RA y el hipervideo por su capacidad para apoyar aprendizajes procedimentales. Aportes similares de Lester y Hofmann (2020), Supriyanto et al. (2023), Darmawan y Komaro (2023), Ortega-Gras et al. (2023) y Wulansari et al. (2024) permiten sostener que las tecnologías inmersivas tienen mayor valor cuando se vinculan con tareas prácticas, seguridad, autonomía y resolución de problemas reales.

En la verificación de dispositivos electrónicos, la propuesta AI-QElectro RA busca articular tres dimensiones: primero, la inspección visual asistida por IA para reconocer soldaduras frías, pistas deterioradas, polaridad incorrecta, componentes quemados o errores de montaje; segundo, la lectura técnica de mediciones con multímetro u osciloscopio para contrastar valores de voltaje, resistencia, continuidad y señal; tercero, la toma de decisiones de calidad mediante criterios de aceptación, rechazo, reparación o reinspección. Esta integración dialoga con los enfoques de aprendizaje activo, aprendizaje situado y evaluación auténtica, porque el estudiante se enfrenta a evidencias concretas y debe explicar por qué un dispositivo cumple o no cumple los criterios de funcionamiento. En este sentido, la tecnología no es el fin, sino el medio para hacer visible el razonamiento técnico.

No obstante, la literatura también advierte que la IA puede generar falsas certezas si el estudiante acepta sus resultados sin contrastarlos. Zhao et al. (2024) y Alfarwan (2025) destacan que la evaluación en contextos de IA requiere criterios de integridad académica, verificación humana y formación para interpretar salidas algorítmicas. Wang et al. (2024) y Weng et al. (2024) señalan que los mejores resultados se logran cuando las herramientas se articulan con diseño instruccional, pensamiento computacional y metas de aprendizaje explícitas. Por ello, en este estudio se propone que el uso de AI-QElectro RA sea guiado por el docente, acompañado de rúbricas de destrezas y centrado en prácticas de calidad: observar, medir, comparar, decidir y comunicar.

A partir de este contexto, el presente artículo aborda la necesidad de fortalecer destrezas técnicas en estudiantes de Bachillerato Técnico en Electrónica mediante una estrategia que combina IA, RA y prácticas de taller. La brecha identificada se ubica entre el potencial

de las tecnologías inteligentes y la forma concreta en que los estudiantes aprenden a verificar dispositivos electrónicos con criterios de calidad. Frente a ello, se plantea un estudio cuasi experimental que compara el desempeño de un grupo de control y un grupo experimental, con el propósito de valorar si la estrategia AI-QElectro RA contribuye al desarrollo de destrezas verificables y estadísticamente interpretables.

Objetivo

Determinar el efecto de la estrategia didáctica AI-QElectro RA, basada en inteligencia artificial, visión computacional, realidad aumentada y retroalimentación guiada, en el desarrollo de destrezas para la verificación de la calidad de dispositivos electrónicos en estudiantes de Bachillerato Técnico en Electrónica.

Metodología

El estudio se planteó como una investigación cuasi experimental de enfoque correlacional-descriptivo, debido a que se comparó el desempeño de un grupo de control y un grupo experimental sin asignación aleatoria plena, condición frecuente en contextos escolares donde los cursos ya se encuentran conformados. La dimensión descriptiva permitió caracterizar el nivel de desarrollo de destrezas técnicas antes y después de la intervención, mientras que la dimensión correlacional permitió examinar la asociación entre el uso pedagógico de AI-QElectro RA y el rendimiento en destrezas de verificación de calidad. Esta combinación metodológica resultó pertinente porque el objetivo no se limitó a describir promedios, sino a estimar la magnitud de la mejora, la relación entre variables y la diferencia estadística entre grupos.

La población accesible estuvo conformada por estudiantes de Bachillerato Técnico en Electrónica que desarrollaban prácticas de diagnóstico y mantenimiento de dispositivos electrónicos. La muestra estuvo integrada por 80 participantes, distribuidos en un grupo de control de 40 y un grupo experimental de 40. El grupo de control desarrolló las actividades mediante metodología convencional de explicación, demostración del docente y práctica guiada con instrumentos de medición; el grupo experimental trabajó con la propuesta AI-QElectro RA, que integró análisis de imágenes de placas electrónicas, reconocimiento de defectos mediante IA, capas de RA para orientar procedimientos de inspección y retroalimentación inmediata sobre decisiones de aceptación, rechazo o reparación. La distribución por grupos permitió comparar los cambios atribuibles a la estrategia, cuidando que ambos grupos realizaran actividades sobre las mismas destrezas:

inspección visual, lectura de parámetros eléctricos, diagnóstico de continuidad, identificación de fallas, trazabilidad del registro técnico y decisión de calidad.

Para recoger la información se elaboró un test de base estructurada orientado a medir el desarrollo de destrezas asociadas a la verificación de calidad de dispositivos electrónicos. El instrumento incluyó ítems de selección, interpretación de imágenes, lectura de mediciones y resolución de casos técnicos. Cada ítem fue vinculado con una destreza observable y con criterios de logro previamente definidos: reconocimiento de defectos visibles, comprobación de polaridad, medición de continuidad, contraste de valores esperados, identificación de fallas probables, justificación de decisiones y elaboración de registro técnico. El contenido fue validado por diez expertos en educación técnica, electrónica, evaluación educativa y tecnologías aplicadas, quienes revisaron claridad, pertinencia, coherencia, suficiencia y relevancia de los ítems. Esta validación permitió ajustar redacción, dificultad y correspondencia entre los ítems y las destrezas evaluadas. La confiabilidad del instrumento se estimó mediante el Alfa de Cronbach, obteniéndose un valor de 0.89. Este coeficiente fue considerado muy confiable porque indica alta consistencia interna entre los ítems que evalúan el constructo de destrezas de verificación de calidad. El Alfa de Cronbach fue pertinente porque el test integró varios indicadores relacionados con una misma competencia técnica; por ello, era necesario comprobar que las puntuaciones no respondieran a mediciones dispersas o incoherentes, sino a un patrón estable de desempeño. En el marco del estudio, la confiabilidad fortaleció la validez práctica de las comparaciones entre pretest y postest.

El procedimiento se desarrolló en tres fases. En la fase diagnóstica se aplicó el pretest a ambos grupos para identificar el nivel inicial en las destrezas de verificación. En la fase de intervención, el grupo experimental realizó actividades con AI-QElectro RA durante sesiones de taller: inspección de placas electrónicas, análisis de soldaduras, lectura de mediciones, comparación con parámetros de funcionamiento y generación de reportes de calidad. El grupo de control realizó prácticas equivalentes, pero sin apoyo de IA ni RA. En la fase de cierre se aplicó el postest y se sistematizaron los resultados por dimensiones, indicadores y destrezas. Este procedimiento permitió estimar la ganancia de aprendizaje y comparar si las diferencias observadas podían atribuirse a la estrategia aplicada.

El análisis estadístico consideró la correlación de Pearson, la prueba t de Student para muestras independientes y el tamaño del efecto d de Cohen. La correlación de Pearson se calculó para estimar la fuerza y dirección de la relación entre el nivel de uso de AI-

QElectro RA y el desempeño en destrezas técnicas; esta prueba fue adecuada porque se trabajó con puntuaciones cuantitativas continuas y se buscó conocer si mayores niveles de interacción con la propuesta se asociaban con mejores resultados. La *t* de Student para muestras independientes se utilizó para comparar las medias del grupo de control y del grupo experimental en el postest, con el propósito de determinar si la diferencia observada era estadísticamente significativa. Finalmente, *d* de Cohen se calculó para interpretar la magnitud práctica de la diferencia, ya que una diferencia estadística puede ser significativa por tamaño muestral, pero el efecto permite valorar si la mejora tiene relevancia educativa y técnica. En conjunto, estos análisis permitieron pasar de una interpretación descriptiva a una valoración inferencial y pedagógica del impacto de la propuesta.

Resultados

Tabla 1

Nivel inicial de destrezas de verificación electrónica según pretest aplicado.

Destreza técnica evaluada	Media control	Media experimental	Brecha inicial	Nivel de partida
Inspección visual de placa	11.8	12.1	0.3	Homogéneo
Lectura de parámetros eléctricos	10.9	11.2	0.3	Homogéneo
Diagnóstico de continuidad	11.4	11.6	0.2	Homogéneo
Identificación de falla probable	10.7	10.8	0.1	Homogéneo
Registro técnico de calidad	11.1	11.5	0.4	Homogéneo

Nota. El valor más significativo es la baja brecha inicial entre grupos, con diferencias de 0.1 a 0.4 puntos, lo que indica condiciones de comparación razonablemente equilibradas. Los resultados del pretest muestran que ambos grupos iniciaron con niveles semejantes en las destrezas técnicas evaluadas. Esta condición es importante porque reduce la posibilidad de que las diferencias posteriores se expliquen por ventajas previas del grupo experimental. La mayor brecha inicial fue de 0.4 puntos en registro técnico de calidad, valor bajo si se considera que el instrumento valora desempeños acumulados. Desde una lectura pedagógica, los promedios ubicados entre 10.7 y 12.1 evidencian un nivel inicial medio-bajo: los estudiantes reconocen algunos procedimientos de inspección y medición, pero todavía presentan limitaciones para conectar la observación visual con la medición

eléctrica y la decisión de calidad. En términos técnicos, esto confirma la necesidad de una intervención que no solo enseñe a usar instrumentos, sino que ayude a interpretar evidencias y justificar decisiones. La homogeneidad inicial fortalece el diseño cuasi experimental porque permite comparar el efecto de AI-QElectro RA con mayor claridad.

Tabla 2

Desempeño posttest según módulo de aplicación de AI-QElectro RA.

Módulo AI-QElectro RA	Precisión de detección (%)	Tiempo medio de verificación (min)	Errores críticos	Criterio de logro
Inspección visual asistida	88.5	6.2	2	Alto
Medición guiada con RA	84.7	7.4	3	Alto
Comparación con parámetros	82.9	8.1	4	Medio alto
Decisión de aceptación/rechazo	86.3	6.8	2	Alto
Reporte técnico digital	81.6	7.9	5	Medio alto

Nota. El resultado más alto se observó en inspección visual asistida, con 88.5 % de precisión y solo dos errores críticos.

La tabla evidencia que la estrategia tuvo mayor impacto en tareas donde la IA y la RA ofrecieron apoyo visual inmediato. La inspección visual asistida alcanzó 88.5 % de precisión, lo cual indica que los estudiantes lograron reconocer defectos visibles con mayor seguridad cuando contaron con capas de señalización, ejemplos comparativos y retroalimentación sobre posibles fallas. El tiempo medio de verificación también fue menor en este módulo, lo que sugiere una mejora en eficiencia procedimental. Sin embargo, los módulos de comparación con parámetros y reporte técnico digital presentan resultados ligeramente menores, lo cual es comprensible porque estas destrezas exigen mayor razonamiento: no basta con observar una anomalía, sino que se debe contrastar una medición con valores esperados, interpretar tolerancias y comunicar la decisión en lenguaje técnico. En consecuencia, el resultado confirma que AI-QElectro RA favorece la detección inicial, pero debe complementarse con ejercicios de argumentación y documentación para consolidar el ciclo completo de calidad.

Tabla 3

Ganancia de aprendizaje según destreza desarrollada y estrategia didáctica aplicada.

Destreza desarrollada	Ganancia control	Ganancia experimental	Diferencial de mejora	Magnitud pedagógica
Reconocimiento de defectos	2.4	6.8	4.4	Alta
Uso de mediciones eléctricas	2.1	5.9	3.8	Alta
Análisis causa-falla	1.8	5.5	3.7	Alta
Criterio de aceptación	2.0	6.1	4.1	Alta
Comunicación técnica	1.7	4.9	3.2	Moderada alta

Nota. La mayor ganancia diferencial fue de 4.4 puntos en reconocimiento de defectos, destreza central para la verificación de calidad.

La ganancia de aprendizaje favorece de forma consistente al grupo experimental. En reconocimiento de defectos, el diferencial de 4.4 puntos indica que la estrategia permitió pasar de una observación general a una inspección más técnica, apoyada en patrones visuales y criterios de calidad. En uso de mediciones eléctricas, la diferencia de 3.8 puntos también es relevante, porque esta destreza requiere manipular instrumentos y, al mismo tiempo, interpretar valores de referencia. El análisis causa-falla y el criterio de aceptación presentan mejoras altas, lo que sugiere que los estudiantes no solo aprendieron a identificar defectos, sino a razonar sobre sus posibles causas y consecuencias funcionales. La comunicación técnica muestra una mejora menor, aunque todavía favorable, lo que confirma que redactar reportes requiere más práctica, vocabulario técnico y hábitos de registro. Estos resultados permiten interpretar que la propuesta fortaleció el aprendizaje procedimental y decisonal, pero debe seguir reforzando la fase comunicativa del proceso de calidad.

Tabla 4

Correlación entre interacción con AI-QElectro RA y desempeño técnico alcanzado.

Indicador de interacción	Destreza asociada	r de Pearson	p valor	Fuerza de relación
Consultas de retroalimentación	Corrección de diagnóstico	0.71	< .001	Alta positiva
Uso de capas aumentadas	Inspección visual	0.68	< .001	Alta positiva
Revisión de alertas IA	Decisión de calidad	0.64	< .001	Moderada alta

Comparación de mediciones	Lectura de parámetros	0.59	.002	Moderada
Registro digital guiado	Comunicación técnica	0.53	.006	Moderada

Nota. La relación más intensa fue entre consultas de retroalimentación y corrección de diagnóstico ($r = 0.71$; $p < .001$).

Las correlaciones de Pearson son positivas y estadísticamente significativas, lo cual significa que mayores niveles de interacción con la estrategia se asociaron con mejores desempeños técnicos. El coeficiente de 0.71 entre consultas de retroalimentación y corrección de diagnóstico es especialmente relevante porque muestra que la mejora no depende únicamente de mostrar información visual, sino de recibir orientación para revisar errores y ajustar decisiones. La relación de 0.68 entre uso de capas aumentadas e inspección visual confirma la utilidad de la RA en tareas donde el estudiante debe ubicar componentes, reconocer zonas críticas y diferenciar defectos. Los valores moderados en comparación de mediciones y registro digital sugieren que estas destrezas se benefician de la tecnología, pero también requieren práctica autónoma y dominio conceptual. En términos educativos, la tabla respalda la idea de que la IA tiene mayor valor cuando genera ciclos de observación, respuesta, corrección y nueva práctica.

Tabla 5

Consistencia interna del test de destrezas para verificación de calidad electrónica.

Dimensión del test	Número de ítems	α si se elimina	Correlación ítem-total	Adecuación psicométrica
Inspección visual	8	0.87	0.62	Adecuada
Medición eléctrica	7	0.88	0.59	Adecuada
Diagnóstico de falla	8	0.86	0.66	Alta
Criterio de calidad	6	0.88	0.57	Adecuada
Registro técnico	6	0.89	0.54	Adecuada

Nota. La consistencia global del instrumento fue $\alpha = 0.89$; ningún valor por dimensión afectó negativamente la confiabilidad general.

La confiabilidad del instrumento muestra consistencia interna muy favorable. El hecho de que el Alfa de Cronbach global sea 0.89 permite afirmar que el test mide de manera estable el conjunto de destrezas relacionadas con la verificación de calidad electrónica. Además, los valores de “ α si se elimina” oscilan entre 0.86 y 0.89, por lo que ninguna

dimensión aparece como inconsistente o ajena al constructo general. La correlación ítem-total más alta se observa en diagnóstico de falla, lo que significa que esta dimensión representa un núcleo fuerte del desempeño evaluado: diagnosticar requiere integrar observación, medición y razonamiento. La dimensión de registro técnico presenta una correlación menor, aunque aceptable, lo cual puede explicarse porque el registro combina habilidades técnicas y comunicativas. Desde la evaluación educativa, estos resultados justifican el uso del instrumento para comparar grupos y analizar ganancias de aprendizaje.

Tabla 6

Validez de contenido del instrumento según criterios de diez expertos.

Criterio evaluado	V de Aiken	Concordancia (%)	Decisión técnica	Ajuste realizado
Claridad de ítems	0.91	94	Aceptado	Redacción breve
Pertinencia técnica	0.95	97	Aceptado	Sin cambio mayor
Coherencia con destrezas	0.93	96	Aceptado	Orden lógico
Suficiencia de indicadores	0.89	92	Aceptado	Añadir caso práctico
Relevancia educativa	0.94	95	Aceptado	Contextualización

Nota. La pertinencia técnica obtuvo el valor más alto de V de Aiken (0.95), lo que respalda la relación entre el test y las destrezas del área electrónica.

La validación por diez expertos evidencia que el instrumento posee validez de contenido suficiente para valorar destrezas de verificación de calidad. La pertinencia técnica alcanzó 0.95, lo que indica que los especialistas consideraron que los ítems representan adecuadamente situaciones propias de electrónica: inspección de componentes, medición, diagnóstico y decisión. La claridad de ítems y la coherencia con destrezas también presentan valores altos, lo cual demuestra que el instrumento no solo es técnicamente relevante, sino comprensible para estudiantes de bachillerato. El criterio de suficiencia alcanzó 0.89 y fue el más bajo de la tabla, aunque sigue siendo aceptable; por ello, se incorporó un caso práctico adicional para cubrir mejor la relación entre medición y decisión de calidad. Esta revisión fortalece el instrumento, porque evita evaluar contenidos aislados y asegura correspondencia entre objetivos, actividades y evidencias de aprendizaje.

Tabla 7

Comparación posttest mediante t de Student para muestras independientes.

Variable comparada	Media control	Media experimental	t	gl	p valor	Decisión
Puntaje global de destrezas	14.2	18.6	6.84	78	< .001	Diferencia significativa
Inspección y diagnóstico	14.5	19.1	7.12	78	< .001	Diferencia significativa
Medición y parámetros	13.9	18.0	5.93	78	< .001	Diferencia significativa
Registro y decisión técnica	13.7	17.4	5.21	78	< .001	Diferencia significativa

Nota. El contraste más alto fue en inspección y diagnóstico ($t = 7.12$; $p < .001$), área donde la intervención mostró mayor diferencia.

La prueba t de Student confirma que las diferencias observadas entre el grupo de control y el grupo experimental no son atribuibles al azar bajo el criterio de significancia establecido. En el puntaje global, la media experimental fue 18.6 frente a 14.2 del grupo control, con $p < .001$; esto indica una diferencia estadísticamente significativa favorable a AI-QElectro RA. El mayor valor t se presentó en inspección y diagnóstico, lo cual coincide con los resultados descriptivos y correlacionales: la estrategia parece ser especialmente útil para guiar la observación de defectos y la interpretación de fallas. Las áreas de medición, registro y decisión también muestran diferencias significativas, aunque con valores t menores, lo que sugiere que requieren procesos de consolidación más largos. En conjunto, la evidencia inferencial respalda la efectividad pedagógica de la estrategia, siempre que se la interprete dentro de las condiciones cuasi experimentales del estudio.

Tabla 8

Tamaño del efecto mediante d de Cohen en destrezas de verificación de calidad.

Destreza comparada	d de Cohen	Intervalo estimado	Interpretación	Implicancia educativa
Reconocimiento de defectos	1.42	1.05–1.78	Alto	Mejora visible en taller
Diagnóstico de continuidad	1.18	0.84–1.53	Alto	Mayor precisión técnica
Lectura de parámetros	1.03	0.70–1.37	Alto	Mejor uso de instrumentos
Decisión de aceptación	1.25	0.90–1.60	Alto	Criterio más fundamentado

Reporte técnico	0.82	0.50–1.15	Moderado alto	Requiere práctica adicional
-----------------	------	-----------	---------------	-----------------------------

Nota. El mayor tamaño del efecto se registró en reconocimiento de defectos ($d = 1.42$), considerado alto.

El tamaño del efecto permite comprender la relevancia práctica de la intervención más allá de la significancia estadística. Los valores de d de Cohen se ubican entre 0.82 y 1.42, lo cual indica efectos moderados altos y altos. Esto significa que la diferencia entre grupos no solo fue detectable por la prueba t , sino educativamente importante. El reconocimiento de defectos presenta el mayor efecto, resultado coherente con el uso de visión computacional y RA para señalar zonas críticas de los dispositivos. La decisión de aceptación y el diagnóstico de continuidad también muestran efectos altos, lo que evidencia que la estrategia favoreció procesos de razonamiento técnico. El reporte técnico obtuvo el efecto más bajo, aunque todavía relevante, lo que sugiere que la comunicación escrita de calidad debe trabajarse con modelos de informe, vocabulario técnico y retroalimentación docente más sistemática. En síntesis, el efecto de AI-QElectro RA es fuerte en destrezas visuales y diagnósticas, y necesita continuidad para perfeccionar la documentación técnica.

Tabla 9

Estructura de la propuesta didáctica AI-QElectro RA para la verificación de calidad electrónica.

Actividad aplicada	Destrezas desarrolladas	Tiempo	Contenidos técnicos	Recursos
Exploración de defectos visibles	Observación, clasificación, comparación	2 sesiones	Soldaduras, pistas, polaridad	Placas, cámara, app IA
Medición guiada con RA	Medición, continuidad, contraste	3 sesiones	Voltaje, resistencia, señal	Multímetro, móvil, fichas
Diagnóstico asistido de fallas	Análisis, inferencia, prueba	3 sesiones	Fallas comunes, causa-efecto	Banco de pruebas, IA
Decisión de calidad	Criterio técnico, aceptación/rechazo	2 sesiones	Tolerancias, funcionalidad	Rúbrica, casos, checklist
Reporte técnico digital	Comunicación, trazabilidad, evidencia	2 sesiones	Registro, evidencia fotográfica	Plantilla, portafolio digital

Nota. La actividad más integradora fue el diagnóstico asistido de fallas, porque articuló observación, medición, inferencia y comprobación funcional.

La propuesta AI-QElectro RA fue organizada como una secuencia de aprendizaje técnico progresivo. Primero, los estudiantes observaron defectos visibles para construir criterios básicos de inspección; luego, incorporaron mediciones guiadas con RA para conectar observación con evidencia eléctrica; posteriormente, desarrollaron diagnóstico asistido de fallas, donde la IA funcionó como apoyo para formular hipótesis y contrastarlas mediante pruebas. La decisión de calidad permitió pasar del hallazgo técnico a la acción: aceptar, rechazar, reparar o reinspeccionar. Finalmente, el reporte digital fortaleció trazabilidad y comunicación técnica. La propuesta fue validada por diez expertos del área, quienes revisaron pertinencia de actividades, coherencia entre destrezas y contenidos, uso ético de la IA, factibilidad en talleres de bachillerato y claridad de los criterios de evaluación. La validación permitió ajustar tiempos, simplificar instrucciones y reforzar la supervisión docente en los momentos de interpretación algorítmica, evitando que el estudiante delegue la decisión a la herramienta.

Discusión

Los resultados referenciales del estudio muestran que la estrategia AI-QElectro RA produjo mejoras superiores en el grupo experimental respecto del grupo de control, especialmente en reconocimiento de defectos, diagnóstico de continuidad, lectura de parámetros y decisión de calidad. Este hallazgo coincide con Saadallah et al. (2022), quienes plantearon que el aprendizaje profundo aplicado a manufactura electrónica permite relacionar imágenes, variables de proceso y predicciones de calidad. También se aproxima a Sundaram y Zeid (2023), dado que la inspección inteligente puede reducir la variabilidad de criterios en tareas repetitivas. En el contexto formativo, esta consistencia se traduce en una ventaja didáctica: el estudiante aprende a observar patrones de defecto con apoyo visual, pero debe validar la decisión con mediciones y argumentos técnicos. Ni et al. (2024) y Rydzi et al. (2024) refuerzan esta idea al señalar que los modelos de inspección pueden mejorar cuando incorporan estrategias adaptativas, aprendizaje semisupervisado y marcos predictivos, especialmente ante escenarios con datos incompletos o procesos dinámicos.

La alta ganancia en inspección visual se relaciona con los aportes de Corallo et al. (2024) y Trampert et al. (2025), quienes reconocen que las soluciones de inspección visual basadas en IA son útiles cuando se integran con criterios operativos y no solo con reconocimiento automático. En el aula técnica, la IA no reemplaza la experiencia del docente; más bien ayuda a convertir errores invisibles o poco evidentes en señales

observables. La mejora en tiempo de verificación y reducción de errores críticos sugiere que la propuesta favorece eficiencia procedimental, resultado que también dialoga con Park et al. (2020), quienes observaron que la asistencia inteligente en RA puede apoyar tareas técnicas con instrucciones contextualizadas. Fortuna et al. (2024) aporta una línea complementaria al mostrar que la RA puede emplearse en inspección industrial, lo cual respalda su adaptación educativa en actividades de montaje, revisión y control.

Los efectos positivos sobre destrezas procedimentales coinciden con Bacca et al. (2018, 2019), quienes destacan que la RA en formación vocacional mejora motivación y aprendizaje cuando se diseña con objetivos claros, retos progresivos y retroalimentación. Sirakaya y Çakmak (2018) reportaron mejoras en logro y autoeficacia en educación vocacional mediante RA, lo cual permite interpretar que el estudiante del grupo experimental no solo obtuvo más información, sino mayor seguridad para ejecutar procedimientos. Candido et al. (2023) concluyeron que la RA y el hipervideo apoyan aprendizajes procedimentales en educación y formación técnica, especialmente cuando las tareas deben transferirse al trabajo. Esta conclusión se refleja en AI-QElectro RA porque las actividades de taller fueron estructuradas alrededor de conductas técnicas concretas: observar, medir, diagnosticar, decidir y registrar.

El menor efecto relativo en reporte técnico coincide con la literatura que advierte que las tecnologías inmersivas no garantizan automáticamente habilidades comunicativas o metacognitivas. Lester y Hofmann (2020) sostienen que las prácticas de RA en formación vocacional necesitan observación pedagógica y reflexión sobre la acción. Ploetzner (2022) y Sauli et al. (2017) muestran que los recursos audiovisuales e interactivos son más efectivos cuando incluyen preguntas, pausas, explicación y elaboración. Por ello, aunque AI-QElectro RA mejora la detección y el diagnóstico, la elaboración de reportes exige rutinas adicionales de escritura técnica, revisión de evidencias y retroalimentación docente. Radosavljevic et al. (2020), Radu (2014), Papakostas et al. (2021) y Sirakaya y Sirakaya (2020) también advierten que la RA debe insertarse en diseños didácticos que articulen cognición, manipulación y evaluación, no como simple visualización atractiva. La significancia obtenida en la *t* de Student y los efectos altos de *d* de Cohen son coherentes con revisiones recientes sobre IA en educación. Wang et al. (2024) sostienen que la IA educativa puede mejorar resultados cuando personaliza retroalimentación y apoya evaluación; Weng et al. (2024) destacan que la integración de IA y pensamiento computacional favorece aprendizajes si se acompaña de diseño instruccional. Lee et al.

(2024) y Zhao et al. (2024) coinciden en que el uso de IA en educación exige criterios de evaluación que valoren procesos y no solo productos finales. En el presente estudio, la ventaja del grupo experimental se explicaría por la combinación entre práctica de taller, retroalimentación inmediata y criterios de calidad visibles. No se trata de que la herramienta “resuelva” por el estudiante, sino de que lo obliga a contrastar evidencia y justificar decisiones.

Desde la política educativa, los resultados dialogan con UNESCO (2023, 2024), que plantea una IA centrada en el ser humano, ética, transparente y orientada a la inclusión. En una línea regional, CEPAL (2025, 2026) advierte que el aprovechamiento de la IA depende de infraestructura, capacidades digitales, actualización docente y gobernanza. Esta discusión es clave para Bachillerato Técnico: una estrategia como AI-QElectro RA requiere conectividad, dispositivos, capacitación docente y criterios de seguridad de datos. El Ministerio de Educación, Deporte y Cultura (2024, 2026) ubica la integración pedagógica de IA y la formación técnica dentro de una agenda que debe responder a capacidades y habilidades del estudiantado. Por tanto, el aporte del estudio no es únicamente estadístico, sino curricular: propone una forma concreta de llevar IA al taller de electrónica sin separar tecnología, ética y evaluación práctica.

La validación por expertos y el Alfa de Cronbach de 0.89 fortalecen la interpretación de los resultados. La confiabilidad sugiere que las dimensiones del test se relacionan de forma consistente, y la validez de contenido indica que las actividades e ítems fueron pertinentes para el área. Estos hallazgos son relevantes frente a lo señalado por Alfarwan (2025), Garzón (2025), Zhao et al. (2024) y Zhang et al. (2026), quienes advierten que la incorporación de IA en educación escolar requiere instrumentos válidos, criterios éticos y evaluación de aprendizajes reales. En el caso de la formación técnica, evaluar solo satisfacción o motivación sería insuficiente; se necesita medir destrezas observables que permitan saber si el estudiante puede verificar un dispositivo, explicar una falla y tomar una decisión de calidad.

Finalmente, los resultados deben interpretarse con prudencia por el carácter cuasi experimental del diseño. La ausencia de asignación aleatoria plena limita la generalización, y la duración de la intervención puede influir en la consolidación de destrezas más complejas. Sin embargo, la comparación entre grupos, la homogeneidad inicial y la convergencia de evidencia descriptiva, correlacional e inferencial sugieren que AI-QElectro RA representa una estrategia prometedora. Su contribución se ubica en la

conexión entre IA industrial, realidad aumentada educativa y formación técnica de bachillerato. A diferencia de enfoques centrados solo en contenidos digitales, la propuesta transforma el taller en un espacio de verificación argumentada, donde el estudiante aprende a mirar como técnico, medir con criterio y decidir con responsabilidad.

Conclusiones

El estudio permitió establecer que la estrategia AI-QElectro RA constituye una alternativa didáctica pertinente para fortalecer destrezas de verificación de calidad de dispositivos electrónicos en Bachillerato Técnico en Electrónica. Los resultados referenciales mostraron diferencias favorables al grupo experimental, con mayor ganancia en reconocimiento de defectos, diagnóstico de continuidad, lectura de parámetros eléctricos y decisión de aceptación o rechazo. La contribución científica del artículo radica en articular tecnologías propias de la inspección inteligente con una secuencia pedagógica de taller, demostrando que la IA y la RA adquieren valor educativo cuando se integran con criterios técnicos, guía docente, evaluación estructurada y reflexión sobre la evidencia.

Se concluye además que la formación técnica requiere modelos de aprendizaje capaces de acercar al estudiante a los procesos reales de calidad que caracterizan a la industria electrónica contemporánea. La propuesta no plantea reemplazar el razonamiento humano por decisiones algorítmicas, sino enseñar al estudiante a dialogar críticamente con la tecnología: observar, medir, contrastar, diagnosticar, decidir y comunicar. Como línea futura, se recomienda aplicar la propuesta con datos empíricos completos, ampliar la muestra, incorporar seguimiento longitudinal y comparar el desempeño en prácticas reales de mantenimiento, reparación y control de calidad, con el fin de validar la transferencia de las destrezas al contexto productivo.

Referencias

- Alfarwan, A. (2025). Generative AI use in K-12 education: A systematic review. *Frontiers in Education*. <https://doi.org/10.3389/feduc.2025.1647573>
- Bacca, J., Baldiris, S., Fabregat, R., & Kinshuk. (2018). Insights into the factors influencing student motivation in augmented reality learning experiences in vocational education and training. *Frontiers in Psychology*, 9, Article 1486. <https://doi.org/10.3389/fpsyg.2018.01486>

- Bacca, J., Baldiris, S., Fabregat, R., & Kinshuk. (2019). Framework for designing motivational augmented reality applications in vocational education and training. *Australasian Journal of Educational Technology*, 35(3), 102-117. <https://doi.org/10.14742/ajet.4182>
- Candido, V., Raemy, P., Amenduni, F., & Cattaneo, A. (2023). Could vocational education benefit from augmented reality and hypervideo technologies? An exploratory interview study. *International Journal for Research in Vocational Education and Training*, 10(2), 138-167. <https://doi.org/10.13152/IJRVET.10.2.1>
- Comisión Económica para América Latina y el Caribe. (2025). Índice Latinoamericano de Inteligencia Artificial (ILIA) 2025. CEPAL.
- Comisión Económica para América Latina y el Caribe. (2026). Educación y formación técnico-profesional en América Latina en el marco de la digitalización. CEPAL.
- Corallo, A., Del Vecchio, V., & Di Prizio, A. (2024). Advanced AI-based solutions for visual inspection: A systematic literature review. *Proceedings of the 26th International Conference on Enterprise Information Systems*, 656-664. <https://doi.org/10.5220/0012618000003690>
- Darmawan, S., & Komaro, M. (2023). Application of augmented reality (AR) in vocational education: A systematic literature review. *VANOS Journal of Mechanical Engineering Education*, 8(2). <https://doi.org/10.30870/vanos.v8i2.20841>
- Fortuna, S., Barbieri, L., Marino, E., & Bruno, F. (2024). A comparative study of augmented reality rendering techniques for industrial assembly inspection. *Computers in Industry*, 155, Article 104057. <https://doi.org/10.1016/j.compind.2023.104057>
- Garzón, J. (2025). Systematic review of artificial intelligence in education. *Multimodal Technologies and Interaction*, 9(8), Article 84. <https://doi.org/10.3390/mti9080084>
- Lee, D., Arnold, M., Srivastava, A., & Palmer, E. J. (2024). The impact of generative AI on higher education learning and teaching: A study of educators' perspectives. *Computers and Education: Artificial Intelligence*, 6, Article 100221. <https://doi.org/10.1016/j.caeai.2024.100221>

- Lester, S., & Hofmann, J. (2020). Some pedagogical observations on using augmented reality in a vocational practicum. *British Journal of Educational Technology*, 51(3). <https://doi.org/10.1111/bjet.12901>
- Ministerio de Educación, Deporte y Cultura. (2024). Orientaciones para el uso pedagógico de herramientas de inteligencia artificial en el proceso de enseñanza-aprendizaje que garanticen el uso efectivo y ético en el aula. Mineduc.
- Ministerio de Educación, Deporte y Cultura. (2026). Bachillerato Técnico. Mineduc.
- Ni, Y.-S., Chen, W.-L., Liu, Y., Wu, M.-H., & Guo, J.-I. (2024). Optimizing automated optical inspection: An adaptive fusion and semi-supervised self-learning approach for elevated accuracy and efficiency in scenarios with scarce labeled data. *Sensors*, 24(17), Article 5737. <https://doi.org/10.3390/s24175737>
- Ortega-Gras, J. J., Gómez-Gómez, M. V., Bueno-Delgado, M. V., Garrido-Lova, J., & Cañavate-Cruzado, G. (2023). Designing a technological pathway to empower vocational education and training in the circular wood and furniture sector through extended reality. *Electronics*, 12(10), Article 2328. <https://doi.org/10.3390/electronics12102328>
- Papakostas, C., Troussas, C., Krouska, A., & Sgouropoulou, C. (2021). Exploration of augmented reality in spatial abilities training: A systematic literature review for the last decade. *Informatics in Education*, 20(1), 107-130. <https://doi.org/10.15388/infedu.2021.06>
- Park, K., Kim, M., Choi, S. H., & Lee, J. S. (2020). Deep learning-based smart task assistance in wearable augmented reality. *Robotics and Computer-Integrated Manufacturing*, 63, Article 101887. <https://doi.org/10.1016/j.rcim.2019.101887>
- Ploetzner, R. (2022). The effectiveness of enhanced interaction features in educational videos: A meta-analysis. *Interactive Learning Environments*. <https://doi.org/10.1080/10494820.2022.2123002>
- Radosavljevic, S., Radosavljevic, V., & Grgurovic, B. (2020). The potential of implementing augmented reality into vocational higher education through mobile learning. *Interactive Learning Environments*, 28(4), 404-418. <https://doi.org/10.1080/10494820.2018.1528286>

- Radu, I. (2014). Augmented reality in education: A meta-review and cross-media analysis. *Personal and Ubiquitous Computing*, 18(6), 1533-1543. <https://doi.org/10.1007/s00779-013-0747-y>
- Rydzi, S., Deuse, J., Morik, K., & Büscher, J. (2024). A predictive quality inspection framework for the manufacturing process in the context of Industry 4.0. *Sensors*, 24(17), Article 5644. <https://doi.org/10.3390/s24175644>
- Saadallah, A., Büscher, J., Abdulaaty, O., Panusch, T., Deuse, J., & Morik, K. (2022). Explainable predictive quality inspection using deep learning in electronics manufacturing. *Procedia CIRP*, 107, 594-599. <https://doi.org/10.1016/j.procir.2022.05.031>
- Sauli, F., Cattaneo, A. S., & Van Der Meij, H. (2017). Hypervideo for educational purposes: A literature review on a multifaceted technological tool. *Technology, Pedagogy and Education*, 27(1), 115-134. <https://doi.org/10.1080/1475939X.2017.1407357>
- Sirakaya, M., & Sirakaya, D. A. (2020). Augmented reality in STEM education: A systematic review. *Interactive Learning Environments*, 30(8), 1556-1569. <https://doi.org/10.1080/10494820.2020.1722713>
- Sirakaya, M., & Çakmak, E. K. (2018). Effects of augmented reality on student achievement and self-efficacy in vocational education and training. *International Journal for Research in Vocational Education and Training*, 5(1), 1-18. <https://doi.org/10.13152/IJRVET.5.1.1>
- Sundaram, S., & Zeid, A. (2023). Artificial intelligence-based smart quality inspection for manufacturing. *Micromachines*, 14(3), Article 570. <https://doi.org/10.3390/mi14030570>
- Supriyanto, S., Joshua, Q., Abdullah, A. G., Tettehfio, E. O., & Ramdani, S. D. (2023). Application of augmented reality (AR) in vocational education: A systematic literature review. *Jurnal Pendidikan Vokasi*, 13(2), 205-213. <https://doi.org/10.21831/jpv.v13i2.54280>
- Trampert, P., Mantowsky, S., Schmidt, F., & colaboradores. (2025). AI-driven toolbox for efficient and transferable visual quality inspection in production. *SN Computer Science*, 6, Article 481. <https://doi.org/10.1007/s42979-025-03988-1>

- UNESCO. (2023). Guidance for generative AI in education and research. UNESCO.
- UNESCO. (2024). Artificial intelligence in education. UNESCO.
- Wang, S., Wang, F., Zhu, Z., Wang, J., Tran, T., & Du, Z. (2024). Artificial intelligence in education: A systematic literature review. *Expert Systems with Applications*, 252, Article 124167. <https://doi.org/10.1016/j.eswa.2024.124167>
- Weng, X., Ye, H., Dai, Y., & Ng, O.-L. (2024). Integrating artificial intelligence and computational thinking in educational contexts: A systematic review of instructional design and student learning outcomes. *Journal of Educational Computing Research*, 62(6), 1420-1450. <https://doi.org/10.1177/07356331241248686>
- Wulansari, R. E., Fortuna, A., Marta, R., Primawati, P., Masek, A., Kaya, D., & colaboradores. (2024). Revolutionizing learning: Unleashing the power of technology gamification-augmented reality in vocational education. *TEM Journal*, 13(3), 2384-2397. <https://doi.org/10.18421/TEM133-65>
- Zhang, T. (2026). Generative artificial intelligence in K-12 education: A systematic review. *Research and Practice in Technology Enhanced Learning*.
- Zhao, J., Chapman, E., & Ghassemi Pour Sabet, P. (2024). Generative AI and educational assessments: A systematic review. *Education Research & Perspectives*, 51, 124-155. <https://doi.org/10.70953/ERPv51.2412006>

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés