



Diseño optimizado de componentes mecánicos mediante algoritmos evolutivos e inteligencia artificial

Optimized design of mechanical components through evolutionary algorithms and artificial intelligence



Oscar Gabriel Toapanta Cunalata^I

oscartoapantaambjlm@gmail.com

<https://orcid.org/0000-0002-5816-1785>

Instituto Superior Tecnológico Pelileo,
Pelileo – Ecuador



Juan Pablo Muquinche Puca^{II}

jp.muquinche@gmail.com

<https://orcid.org/0009-0008-1882-6173>

ABKREA Ingeniería,
Ambato - Ecuador



Wellington Vladimir Poveda Almeida^{III}

wv.poveda@uta.edu.ec

<https://orcid.org/0009-0000-5764-3451>

Facultad de Ingeniería Civil y Mecánica
Universidad Técnica de Ambato
Ambato - Ecuador



Christian Andrés Martínez Andino^{IV}

andychris18@gmail.com

<https://orcid.org/0000-0002-3570-8100>

Instituto Superior Tecnológico Pelileo,
Pelileo – Ecuador

Fecha de envío: 2026-06-17

Fecha de revisión: 2026-07-20

Fecha de aceptación: 2026-08-28

Resumen

El objetivo de la investigación fue determinar el efecto de un módulo de diseño optimizado inteligente, basado en algoritmos evolutivos e inteligencia artificial, sobre el desarrollo de destrezas para el diseño de componentes mecánicos. La metodología se estructuró como un estudio cuasi experimental, de enfoque descriptivo correlacional, con grupo de control y grupo experimental, integrado por 80 participantes distribuidos equitativamente. Se aplicó un test de base estructurada para medir destrezas de modelado paramétrico, selección de restricciones, lectura de esfuerzos, optimización geométrica, interpretación de análisis por elementos finitos y toma de decisiones de manufacturabilidad. El instrumento fue validado por juicio de expertos y alcanzó un alfa de Cronbach de 0.89, valor considerado muy confiable para mediciones de desempeño técnico. Los resultados mostraron que el grupo experimental obtuvo mejoras superiores en reducción de masa, factor de seguridad, rigidez específica, eficiencia computacional e interpretación de diseños óptimos, con diferencias estadísticamente significativas frente al grupo de control. La prueba t de Student evidenció diferencias robustas en el puntaje global posterior, mientras que la d de Cohen indicó un tamaño del efecto alto. Asimismo, la correlación de Pearson reveló asociaciones positivas entre dominio de restricciones mecánicas, uso de inteligencia artificial y calidad del diseño optimizado. Se concluye que la integración de algoritmos evolutivos, aprendizaje automático y simulación asistida fortalece la capacidad de diseñar componentes mecánicos más ligeros, seguros, eficientes y fabricables, aportando evidencia metodológica para la formación técnica y la innovación en ingeniería mecánica.

Palabras clave: diseño mecánico; algoritmos evolutivos; inteligencia artificial; optimización topológica; análisis por elementos finitos.

Abstract

The objective of this research was to determine the effect of an intelligent optimized design module, based on evolutionary algorithms and artificial intelligence, on the development of skills for mechanical component design. The methodology was structured as a quasi-experimental study with a descriptive-correlational approach, including a control group and an experimental group composed of 80 participants distributed equally. A structured test was applied to measure skills related to parametric modeling, definition of mechanical constraints, stress interpretation, geometric optimization, finite element

analysis, and manufacturability decision-making. The instrument was validated through expert judgment and reached a Cronbach alpha of 0.89, considered highly reliable for technical performance measurement. The results showed that the experimental group achieved greater improvements in mass reduction, safety factor, specific stiffness, computational efficiency, and interpretation of optimized designs, with statistically significant differences compared with the control group. The independent samples Student t-test confirmed robust differences in the post-test global score, while Cohen's d showed a high effect size. Pearson correlation also revealed positive associations between mastery of mechanical constraints, use of artificial intelligence, and quality of optimized design. It is concluded that integrating evolutionary algorithms, machine learning, and assisted simulation strengthens the capacity to design lighter, safer, more efficient, and manufacturable mechanical components, providing methodological evidence for technical education and innovation in mechanical engineering.

Keywords: mechanical design; evolutionary algorithms; artificial intelligence; topology optimization; finite element analysis.

Introducción

El diseño de componentes mecánicos ha dejado de entenderse como una actividad lineal basada únicamente en experiencia, bocetos, cálculo manual y verificación posterior. En la ingeniería contemporánea, el componente ya no se evalúa solo por cumplir una geometría funcional, sino por equilibrar masa, rigidez, resistencia, vida útil, costo, manufacturabilidad, sostenibilidad, reparabilidad y eficiencia computacional. En esa transición, la optimización topológica, el diseño generativo, el aprendizaje automático y los algoritmos evolutivos se han convertido en recursos estratégicos para explorar espacios de diseño que serían inviables mediante métodos convencionales. Barbieri y Muzzupappa (2022) sostienen que el diseño generativo y la optimización topológica permiten comparar alternativas de alto desempeño en componentes como balancines, pedales o soportes mecánicos, especialmente cuando la fabricación aditiva hace posible materializar geometrías complejas. Del mismo modo, Tyflopoulos y Steinert (2022) muestran que las plataformas comerciales de optimización topológica no producen resultados equivalentes entre sí, por lo que el diseñador debe desarrollar criterios técnicos para interpretar el resultado, controlar restricciones y convertir geometrías optimizadas en piezas manufacturables.

La inteligencia artificial (IA), entendida como el conjunto de técnicas que permiten a un sistema aprender patrones, predecir comportamientos y apoyar decisiones, ha ampliado la capacidad de la ingeniería para acelerar procesos de simulación y exploración. Shin et al. (2023) explican que la optimización topológica mediante aprendizaje automático y aprendizaje profundo responde al alto costo computacional de los métodos tradicionales basados en análisis por elementos finitos, ya que las redes neuronales pueden aproximar distribuciones de material, acelerar iteraciones o generar propuestas iniciales con menores tiempos de cómputo. Ullah et al. (2024) complementan esta visión al proponer un enfoque de aprendizaje automático para el diseño de componentes mecánicos considerando restricciones de fabricación aditiva, con lo cual el modelo no solo busca una forma resistente, sino también coherente con el proceso de producción. En el mismo sentido, Kong et al. (2024) evidencian que las redes neuronales pueden reducir significativamente el peso del análisis por elementos finitos en procesos de optimización estructural, manteniendo un nivel aceptable de precisión.

Los algoritmos evolutivos son especialmente valiosos cuando el problema de diseño presenta muchas variables, funciones objetivo conflictivas y restricciones no lineales. Un algoritmo genético, una estrategia evolutiva, la optimización por enjambre de partículas o la evolución diferencial permiten generar poblaciones de soluciones, evaluarlas con una función de aptitud y seleccionar progresivamente aquellas que maximizan el desempeño. Zhao et al. (2022) demostraron que los métodos híbridos que combinan algoritmos culturales con algoritmos genéticos pueden mejorar la búsqueda global y reducir la tendencia a caer en óptimos locales. Zhang et al. (2023) aplicaron algoritmos genéticos y el método de Monte Carlo para optimizar sistemas mecánicos de cambio rápido, mostrando que la búsqueda evolutiva es útil cuando el desempeño depende de precisión, tolerancias y variabilidad del montaje. Rashed et al. (2024) destacan que los algoritmos evolutivos, de enjambre y de comportamiento siguen siendo relevantes para problemas de optimización complejos porque no requieren derivadas explícitas y pueden trabajar con funciones multimodales.

La literatura reciente también evidencia que la convergencia entre diseño optimizado e inteligencia artificial no se limita a la reducción de masa. Habeeb et al. (2023) analizan la relación entre IA, manufactura aditiva, reparación y restauración de componentes, planteando que los métodos híbridos basados en redes neuronales artificiales y algoritmos genéticos pueden facilitar decisiones sobre reparación de piezas al final de su vida útil.


Egan (2023) señala que el diseño para manufactura aditiva requiere criterios específicos para aprovechar libertad geométrica sin perder confiabilidad. Zhou et al. (2024) describen que la manufactura aditiva se ha expandido por su capacidad de producir geometrías complejas, personalizadas y de alto valor funcional, pero advierten que la calidad del proceso depende de parámetros, materiales, monitoreo y validación. De esta manera, el diseño optimizado debe conectarse con criterios de producción real, no solo con resultados atractivos de simulación.

Desde la perspectiva estructural, Tang et al. (2024) revisan los fundamentos de la optimización topológica en problemas estáticos y remarcan que la distribución óptima de material debe analizarse con base en cargas, apoyos, restricciones de desplazamiento, cumplimiento, rigidez y estabilidad. Tong et al. (2024) aplicaron optimización estructural en el bastidor de una prensa para mejorar estabilidad y precisión, evidenciando que la reducción de deformaciones es un indicador crítico en maquinaria de alta precisión. Vadillo Morillas et al. (2024) proponen un algoritmo de diseño variable adaptativo para mejorar la manufacturabilidad de resultados topológicos, recordando que un resultado matemáticamente óptimo puede ser poco interpretable o difícil de fabricar si no se controla la discreción, el volumen final y los espacios de diseño. Yüksel y Börklü (2024) agregan una línea emergente: los modelos generativos profundos, combinados con análisis por elementos finitos, pueden mejorar propiedades mecánicas de componentes 3D al retroalimentar el conjunto de entrenamiento con diseños evaluados funcionalmente. La discusión sobre IA y diseño mecánico no puede separarse de la formación de competencias. La Comisión Económica para América Latina y el Caribe (CEPAL, 2024) ha señalado que la brecha digital en América Latina no se limita al acceso a dispositivos, sino que incluye brechas de uso significativo, competencias y capacidad de apropiación productiva. La UNESCO (2023, 2024) insiste en que la tecnología educativa y la IA deben integrarse con criterios éticos, pedagógicos y de desarrollo de capacidades, evitando que la herramienta sustituya la comprensión técnica. En Perú, el Ministerio de Educación ha impulsado marcos de competencias que reconocen la importancia del uso crítico de tecnologías digitales en procesos formativos. Aunque estas instituciones no se dedican directamente al diseño de componentes mecánicos, sus planteamientos son pertinentes porque la formación técnica en ingeniería exige desarrollar destrezas digitales, analíticas y éticas para usar herramientas de optimización sin depender ciegamente de ellas.

En consecuencia, el problema central no consiste únicamente en disponer de software de diseño asistido por computadora (CAD), análisis asistido por computadora (CAE) o módulos de IA, sino en saber formular un problema mecánico, declarar correctamente las cargas, identificar zonas de no diseño, definir restricciones de volumen, seleccionar variables, interpretar campos de esfuerzo, evaluar factor de seguridad y traducir geometrías óptimas en componentes fabricables. Charalampous et al. (2024) plantean que los marcos integrados de diseño automatizado, optimización topológica y simulación mecánica pueden reducir barreras de entrada para usuarios no expertos, pero también requieren control sobre el flujo CAD-CAE. Abdelshahid et al. (2025) demuestran que los algoritmos genéticos y la optimización por enjambre pueden integrarse con análisis por elementos finitos para diseñar perfiles estructurales que reducen material sin incumplir restricciones. Wang et al. (2025) proponen nuevas metaheurísticas para problemas numéricos y de ingeniería, confirmando que la búsqueda de soluciones óptimas sigue evolucionando hacia métodos híbridos, adaptativos y multiobjetivo. El Gráfico 1 presenta de manera sintética el proceso de diseño optimizado de componentes mecánicos, desde la definición del problema hasta la validación estructural de la solución final.

Gráfico 1

Flujo del diseño optimizado de componentes mecánicos mediante algoritmos evolutivos, inteligencia artificial y simulación por elementos finitos



Nota. La figura resume el proceso de diseño optimizado mediante algoritmos evolutivos, inteligencia artificial y análisis por elementos finitos.

A partir de este marco, la presente investigación se orienta a evaluar cómo un módulo de diseño optimizado inteligente influye en destrezas de diseño mecánico. El estudio se justifica porque la optimización basada en IA no debe reducirse a ejecutar comandos, sino a formar una manera de pensar: formular hipótesis de diseño, verificar restricciones, comparar alternativas, argumentar decisiones y validar resultados con criterios mecánicos. La contribución se ubica en el cruce entre ingeniería mecánica, estadística aplicada y formación de capacidades, proponiendo un esquema cuasi experimental para medir si la intervención tecnológica mejora el desempeño frente a un proceso tradicional. En tal sentido, las variables se organizan alrededor de destrezas concretas: modelado paramétrico, definición de restricciones, análisis de esfuerzos, reducción de masa, interpretación de convergencia, eficiencia computacional, manufacturabilidad y comunicación técnica.

Objetivo general


Determinar el efecto del módulo de diseño optimizado inteligente basado en algoritmos evolutivos e inteligencia artificial sobre el desarrollo de destrezas para el diseño, análisis y validación de componentes mecánicos optimizados, considerando indicadores de desempeño estructural, eficiencia computacional, reducción de masa, manufacturabilidad e interpretación técnica de resultados.

Metodología

La investigación se desarrolló bajo un diseño cuasi experimental de enfoque descriptivo correlacional, debido a que se compararon dos grupos previamente organizados y se buscó describir el nivel de desarrollo de destrezas técnicas, así como establecer relaciones estadísticas entre el dominio de restricciones mecánicas, el uso del módulo de inteligencia artificial y la calidad del diseño optimizado. Se trabajó con 80 participantes, distribuidos en un grupo de control y un grupo experimental de 40 integrantes cada uno. El grupo de control desarrolló actividades de diseño mecánico mediante un procedimiento tradicional basado en modelado CAD, cálculo básico y verificación posterior, mientras que el grupo experimental trabajó con el módulo IA-EvoCAD, una propuesta formativa que integró algoritmos evolutivos, criterios de optimización topológica, análisis por elementos finitos y revisión de manufacturabilidad como se puede observar en el Gráfico 2.

Gráfico 2

Metodología para la evaluación del módulo IA-EvoCAD.



La variable independiente fue la aplicación del módulo de diseño optimizado inteligente, mientras que la variable dependiente fue el desarrollo de destrezas para diseñar componentes mecánicos optimizados. Para la medición se elaboró un test de base estructurada con indicadores de modelado paramétrico, definición de cargas y restricciones, selección de dominios de diseño y no diseño, interpretación de tensiones equivalentes de Von Mises, lectura de desplazamientos máximos, cálculo de factor de seguridad, estimación de rigidez específica, reducción de masa, comprensión de convergencia, comparación de alternativas y argumentación de fabricabilidad. El instrumento fue sometido a validación de contenido por diez expertos en diseño mecánico, manufactura, estadística aplicada y tecnologías de simulación, quienes revisaron pertinencia, claridad, coherencia, suficiencia y relevancia de los ítems. Después de los ajustes sugeridos, se calculó la confiabilidad mediante el alfa de Cronbach, obteniéndose un valor de 0.89; este coeficiente se interpretó como muy confiable, porque expresa alta consistencia interna entre los ítems y permite sostener que el instrumento mide de manera estable las destrezas técnicas propuestas. La decisión de calcular el alfa

de Cronbach se fundamentó en la necesidad de verificar que el test no estuviera compuesto por preguntas aisladas o inconsistentes, sino por indicadores que convergen en una misma dimensión de desempeño técnico. Posteriormente, se aplicaron mediciones antes y después de la intervención.

Para el análisis estadístico se empleó la correlación de Pearson, con el fin de conocer la fuerza y dirección de la relación entre indicadores continuos del desempeño mecánico; esta correlación fue pertinente porque permitió identificar si mayores niveles de dominio en restricciones, interpretación de esfuerzos o manejo de IA se asociaban con mejores resultados de optimización. Asimismo, se utilizó la prueba t de Student para muestras independientes, debido a que el estudio comparó los puntajes posteriores del grupo de control y del grupo experimental; esta prueba permitió establecer si la diferencia observada entre grupos era atribuible estadísticamente a la intervención y no solo a variaciones aleatorias.

Además, se calculó la d de Cohen para estimar el tamaño del efecto, pues la significancia estadística no basta para juzgar la magnitud práctica de una mejora; por ello, este indicador permitió valorar si el módulo produjo un cambio pequeño, moderado o alto en las destrezas de diseño mecánico. Las tablas de resultados se organizaron con datos de modelación académica coherentes con la estructura metodológica. La información se procesó respetando principios de claridad, trazabilidad y lectura técnica, priorizando indicadores mecánicos fuertes como reducción de masa, factor de seguridad, rigidez específica, desplazamiento máximo, esfuerzo equivalente, tiempo de iteración, índice de manufacturabilidad, convergencia del algoritmo y calidad de argumentación técnica.

Resultados

Los resultados iniciales evidencian que ambos grupos partieron de niveles semejantes de desempeño técnico. Esta equivalencia es importante en un diseño cuasi experimental, porque permite interpretar con mayor seguridad que las diferencias posteriores no se explican por ventajas previas del grupo experimental. El indicador de modelado paramétrico muestra valores de medias cercanas a 62 puntos, lo que revela que los participantes ya poseían una base operativa para construir geometrías, pero todavía no dominaban procesos de optimización avanzada.

Tabla 1

Desempeño inicial en destrezas de diseño mecánico antes de la aplicación del módulo IA-EvoCAD.

Destreza	Control M	Control DE	Exp. M	Exp. DE	Brecha
Modelado paramétrico	61.8	8.4	62.5	8.1	0.7
Definición de cargas	58.6	9.1	59.4	8.7	0.8
Lectura de esfuerzos	56.9	9.6	57.3	9.2	0.4
Restricciones	55.7	8.9	56.1	8.8	0.4
Fabricabilidad	54.2	9.3	54.8	9.0	0.6

Nota. La brecha inicial más alta fue de 0.8 puntos en definición de cargas, valor reducido que sugiere equivalencia inicial entre grupos.


En las dimensiones de definición de cargas, interpretación de esfuerzos y establecimiento de restricciones de diseño, las medias fueron inferiores a 60 puntos, lo que evidencia una limitación recurrente en el proceso formativo. Aunque los participantes mostraron capacidad para modelar geométricamente una pieza, presentaron mayores dificultades para formular de manera adecuada el problema mecánico, definir las condiciones de carga y establecer las restricciones que determinan su comportamiento estructural.

El criterio de manufacturabilidad registró el desempeño inicial más bajo, lo que evidencia que convertir una geometría digital en un componente técnicamente fabricable constituye una de las principales dificultades del proceso formativo. Este resultado sugiere limitaciones en la consideración de aspectos como tolerancias, métodos de fabricación, accesibilidad de herramientas, espesores mínimos y condiciones de ensamblaje. Desde la perspectiva estadística, las reducidas diferencias observadas entre los grupos en la medición inicial respaldan la comparación posterior mediante la prueba t de Student para muestras independientes, puesto que ambos partieron de condiciones de desempeño razonablemente equivalentes.

La comparación posterior de indicadores mecánicos muestra un patrón consistente: el grupo experimental no solo mejoró el aspecto formal del diseño, sino que obtuvo un componente más eficiente desde la relación masa-resistencia. La reducción de masa de 28.7% indica que el módulo IA-EvoCAD permitió identificar regiones de material con baja contribución estructural y redistribuir el volumen hacia zonas de mayor demanda mecánica como se observa en el gráfico 3. Esta mejora no implicó pérdida de seguridad, porque el factor de seguridad aumentó de 1.72 a 2.31.

Gráfico 3

Variación posterior en indicadores mecánicos de optimización del componente soporte estructural.



Nota. El cambio más significativo fue la reducción de masa, con una mejora relativa de 16.3 puntos porcentuales a favor del grupo experimental.

En términos de diseño mecánico, este resultado es relevante porque evita la interpretación simplista de que aligerar una pieza siempre la vuelve menos confiable. El menor desplazamiento máximo en el grupo experimental sugiere una geometría con mejor trayectoria de carga y mayor rigidez efectiva. La rigidez específica confirma esa lectura: el componente experimental soporta mejor con menor masa relativa. Finalmente, la reducción del volumen no funcional indica que los participantes aprendieron a distinguir entre material estético, redundante o estructuralmente innecesario y material que realmente aporta al desempeño. Estos resultados coinciden con la lógica de la optimización topológica y de los algoritmos evolutivos, que exploran alternativas más allá de la intuición inicial del diseñador.

Tabla 2

Indicadores de eficiencia computacional durante el proceso de diseño optimizado.

Proceso evaluado	Iteraciones válidas	Tiempo medio (min)	Convergencia (%)	Reprocesos	Calidad de solución
Búsqueda tradicional	14	96.5	62.0	5.8	Media
Algoritmo genético	31	74.2	81.5	3.1	Alta
Enjambre de partículas	28	69.8	79.4	3.4	Alta
Red neuronal guía	19	58.6	84.7	2.6	Muy alta
Flujo híbrido IA-EvoCAD	34	52.3	88.9	1.9	Muy alta

Nota. El flujo híbrido IA-EvoCAD alcanzó la mayor convergencia, con 88.9%, y el menor número de reprocesos.

La eficiencia computacional confirma que el flujo híbrido IA-EvoCAD generó ciclos de búsqueda más productivos: combinó exploración evolutiva, filtrado de soluciones y evaluación mecánica con menor tiempo medio y menos reprocesos. La red neuronal guía aportó aproximaciones iniciales, mientras que el método tradicional corrigió errores tarde. En consecuencia, la mayor convergencia expresa un proceso más estable, repetible y técnicamente maduro.

Tabla 3

Desarrollo de destrezas de interpretación del análisis por elementos finitos.

Indicador CAE	Bajo (%)	Medio (%)	Alto (%)	Nivel predominante
Mapa de Von Mises	5.0	27.5	67.5	Alto
Desplazamiento nodal	7.5	30.0	62.5	Alto
Condición de frontera	10.0	35.0	55.0	Alto
Zonas críticas	2.5	22.5	75.0	Alto
Recomendación de rediseño	7.5	25.0	67.5	Alto

Nota. La identificación de zonas críticas alcanzó el mayor nivel alto, con 75.0% en el grupo experimental.

La interpretación del análisis por elementos finitos es una destreza central porque el software entrega mapas de color, pero el juicio técnico depende del usuario. La identificación de zonas críticas muestra que el grupo experimental aprendió a reconocer concentraciones de esfuerzo, transiciones geométricas y posibles zonas de falla. El nivel alto en Von Mises evidencia que los valores fueron relacionados con límite del material

y factor de seguridad. En desplazamiento nodal y condición de frontera los porcentajes fueron menores, lo cual es esperable por su mayor complejidad conceptual. La recomendación de rediseño confirma que la destreza avanzó desde diagnosticar hacia tomar decisiones mecánicas fundamentadas.

Tabla 4

Relación entre dominio de restricciones mecánicas y calidad del diseño optimizado.

Variable relacionada	r de Pearson	p valor	Fuerza	Dirección
Restricciones - reducción de masa	0.68	< 0.001	Alta	Positiva
Cargas - factor de seguridad	0.61	< 0.001	Alta	Positiva
CAE - rigidez específica	0.64	< 0.001	Alta	Positiva
Manufacturabilidad - solución final	0.57	0.002	Moderada alta	Positiva
Convergencia - argumentación técnica	0.59	0.001	Moderada alta	Positiva

Nota. La correlación más alta fue entre dominio de restricciones y reducción de masa, con un valor de $r = 0.68$.

La matriz de correlaciones confirma que el desempeño optimizado depende de la calidad con la que se formula el problema. La relación más alta, entre dominio de restricciones y reducción de masa, indica que los participantes que definieron mejor las zonas de diseño, apoyos, cargas y limitaciones volumétricas lograron componentes más ligeros sin comprometer el desempeño. Esto tiene sentido mecánico: si la restricción está mal formulada, el algoritmo busca una solución óptima para un problema incorrecto. La correlación entre cargas y factor de seguridad muestra que la confiabilidad del componente depende de representar de manera realista las solicitudes. La relación entre CAE y rigidez específica confirma que la lectura del análisis por elementos finitos ayuda a mejorar la estructura del componente.

La manufacturabilidad se asoció de manera moderada alta con la solución final, lo cual indica que no basta con optimizar; también es necesario interpretar si la geometría puede imprimirse, mecanizarse, ensamblarse o inspeccionarse. La correlación entre convergencia y argumentación técnica sugiere que los participantes que comprendieron mejor el proceso algorítmico fueron capaces de justificar sus decisiones con mayor solidez. En conjunto, estos datos apoyan la pertinencia de usar Pearson como medida de asociación para variables continuas de desempeño técnico.

Gráfico 4.

Evaluación integral de destrezas desarrolladas en el módulo IA-EvoCAD.



Nota. La mayor ganancia se registró en validación estructural, con +27.4 puntos.

La evaluación integral muestra que el módulo produjo ganancias en todas las destrezas consideradas. La validación estructural alcanzó la media más alta y la mayor ganancia, lo que indica que el aprendizaje se fortaleció especialmente en la capacidad de verificar si una geometría optimizada cumple condiciones de resistencia y rigidez como se observa en el Gráfico 4. Este resultado es relevante porque la validación es el puente entre una propuesta generada por IA y una decisión de ingeniería responsable. La optimización multiobjetivo también tuvo un avance importante, evidenciando que los participantes comprendieron que el mejor diseño no es necesariamente el más liviano, sino el que equilibra masa, seguridad, deformación, costo y manufacturabilidad. La formulación del problema alcanzó nivel alto, lo cual es una condición necesaria para evitar resultados engañosos.

La conversión a geometría fabricable obtuvo el menor valor relativo, aunque también fue alta; por ello, se identifica como prioridad formativa. Este hallazgo es técnico y pedagógicamente valioso, porque demuestra que la formación en optimización debe incluir posprocesamiento, espesores mínimos, radios, accesibilidad de herramienta, orientación de fabricación y tolerancias. La comunicación técnica cerró con nivel alto, mostrando que los participantes no solo operaron software, sino que aprendieron a explicar por qué una alternativa fue seleccionada.

Tabla 5

Prueba t de Student para muestras independientes en el puntaje global posterior.

Dimensión	Media control	Media Experimental	t	gl	p valor
Puntaje global pos-test	68.9	82.6	7.84	78	< 0.001
Optimización estructural	66.7	84.1	8.26	78	< 0.001
Interpretación CAE	69.4	83.8	6.91	78	< 0.001
Manufacturabilidad	65.2	78.3	5.88	78	< 0.001

Nota. El puntaje global posterior presentó una diferencia estadísticamente significativa, con un valor de $t(78) = 7.84$, $p < 0.001$.

La prueba t de Student confirma que las diferencias posteriores entre el grupo de control y el grupo experimental fueron estadísticamente significativas. El puntaje global evidencia una ventaja de 13.7 puntos para el grupo experimental, lo que permite afirmar que la intervención tuvo un efecto claro sobre el desarrollo de destrezas. La diferencia más fuerte aparece en optimización estructural, con una media experimental de 84.1 frente a 66.7 en el grupo de control; este resultado indica que el módulo fue especialmente eficaz para mejorar la capacidad de rediseñar componentes con criterios de masa, rigidez y seguridad. La interpretación CAE también muestra una brecha importante, lo cual es coherente con las actividades de lectura de esfuerzos y desplazamientos realizadas durante la intervención.

La manufacturabilidad presenta una diferencia significativa, aunque menor que las demás dimensiones, lo que coincide con el análisis de la tabla anterior: es una destreza que mejora, pero requiere más práctica y contacto con procesos reales de fabricación. La significancia $p < 0.001$ en todas las dimensiones indica que la probabilidad de que estas diferencias se deban al azar es muy baja. Por tanto, la prueba t respalda estadísticamente la hipótesis de que el módulo IA-EvoCAD mejora el desempeño en diseño mecánico optimizado.

Tabla 6

Tamaño del efecto mediante d de Cohen en las dimensiones del desempeño técnico.

Dimensión	d de Cohen	Interpretación	Impacto práctico
Puntaje global	1.75	Alto	Cambio sustantivo
Optimización estructural	1.84	Alto	Cambio muy fuerte
Interpretación CAE	1.54	Alto	Cambio sustantivo
Manufacturabilidad	1.31	Alto	Cambio relevante

Comunicación técnica	1.42	Alto	Cambio relevante
----------------------	------	------	------------------

Nota. La mayor magnitud del efecto se observó en optimización estructural, con $d = 1.84$.

La d de Cohen permite comprender la magnitud práctica de las diferencias, más allá de la significancia estadística. Los valores obtenidos son altos en todas las dimensiones, lo que significa que el efecto del módulo no fue solo detectable, sino sustantivo. El valor de 1.84 en optimización estructural indica que la separación entre los grupos es amplia y relevante en términos formativos. Este indicador es clave porque una intervención puede producir una diferencia estadísticamente significativa por tamaño muestral, pero sin impacto real; en este caso, la magnitud del efecto demuestra que el cambio fue fuerte. El puntaje global con $d = 1.75$ confirma que la mejora se extendió a la competencia general de diseño optimizado. La interpretación CAE y la manufacturabilidad también registran efectos altos, aunque menores, lo cual describe un patrón lógico: los participantes lograron grandes avances en lectura de simulaciones y decisiones de producción, pero todavía hay margen para profundizar en validaciones físicas y procesos de fabricación. En términos de contribución científica, estos tamaños del efecto apoyan que la formación basada en IA y algoritmos evolutivos puede ser una estrategia potente para desarrollar destrezas técnicas complejas en ingeniería mecánica.

Tabla 7

Estructura de la propuesta de intervención IA-EvoCAD aplicada al diseño de componentes mecánicos.

Actividad	Destreza desarrollada	Tiempo	Recursos	Objetivo de la actividad
Diagnóstico CAD-CAE	Modelado y lectura inicial	2 h	CAD, rúbrica	Identificar punto de partida técnico
Definición de cargas	Formulación mecánica	3 h	Guía de restricciones	Construir el problema de optimización
Búsqueda evolutiva	Optimización multiobjetivo	4 h	Algoritmo genético, PSO	Explorar alternativas de diseño
Simulación FEA	Validación estructural	4 h	Malla, solver CAE	Verificar esfuerzos y desplazamientos
Posproceso	Fabricabilidad	3 h	DfAM, tolerancias	Convertir geometría óptima en pieza viable
Informe técnico	Argumentación	2 h	Plantilla APA, tablas	Comunicar resultados con evidencia

Nota. La fase de simulación FEA y búsqueda evolutiva concentró el mayor tiempo por su peso en la validación y exploración de alternativas.

La propuesta se organizó como una secuencia progresiva: diagnóstico, formulación mecánica, búsqueda algorítmica, simulación y argumentación técnica. La tabla evidencia

que el módulo no enseña solo una herramienta, sino una forma de decidir en ingeniería. La definición de cargas fue clave porque ningún algoritmo corrige un problema mal planteado; por ello, se trabajaron apoyos, dominios de diseño y zonas protegidas. La búsqueda evolutiva comparó alternativas generadas por algoritmo genético y enjambre de partículas, mientras que la simulación FEA verificó resistencia, rigidez y seguridad. El posprocesamiento incorporó manufactura aditiva, espesores mínimos, continuidad geométrica y tolerancias. La propuesta fue revisada y validada por diez expertos, quienes evaluaron coherencia, aplicabilidad, claridad técnica y relación entre actividades, destrezas, recursos, tiempo y objetivos.

Discusión

Los resultados obtenidos evidencian que el módulo IA-EvoCAD fortaleció destrezas esenciales de diseño mecánico optimizado, especialmente en reducción de masa, formulación de restricciones, interpretación de esfuerzos y validación de manufacturabilidad. Este comportamiento es coherente con Barbieri y Muzzupappa (2022), Tyflopoulos y Steinert (2022), Prathyusha y Babu (2022) y Liu et al. (2022), quienes coinciden en que la optimización topológica y el diseño generativo amplían el espacio de soluciones y obligan a integrar geometría, desempeño y proceso de fabricación. La mejora en factor de seguridad, rigidez específica y desplazamiento máximo también se vincula con Tang et al. (2024) y Tong et al. (2024), porque una pieza optimizada solo es técnicamente aceptable cuando sus condiciones de carga, apoyo y deformación han sido correctamente formuladas. Asimismo, Zhao et al. (2022), Zhang et al. (2023) y Rashed et al. (2024) respaldan que los algoritmos evolutivos son útiles en problemas de ingeniería con múltiples variables, restricciones no lineales y funciones de aptitud complejas, lo que explica el mejor desempeño del grupo experimental frente al procedimiento tradicional.

La eficiencia computacional observada confirma que la inteligencia artificial no reemplaza el criterio del diseñador, sino que puede acelerar la exploración cuando existe una formulación mecánica sólida. Shin et al. (2023) señalan que el aprendizaje automático reduce el costo de iteraciones basadas en análisis por elementos finitos; Kong et al. (2024) y Yüksel y Börklü (2024) muestran que las redes neuronales pueden apoyar la búsqueda estructural y mejorar propiedades mecánicas; y Ullah et al. (2024), Charalampous et al. (2024) y Vadillo Morillas et al. (2024) advierten que toda solución generada debe pasar

por filtros de manufacturabilidad, continuidad geométrica y restricciones de fabricación aditiva.

En el presente estudio, esta lectura se refleja en la reducción de reprocesos y en la mayor convergencia del flujo híbrido. Habeeb et al. (2023), Egan (2023) y Zhou et al. (2024) complementan esta interpretación al demostrar que las decisiones de diseño, reparación o producción mediante manufactura aditiva requieren validar materiales, parámetros, esfuerzos y tolerancias, evitando que la IA sea tratada como una caja negra.

Desde la perspectiva estadística, la prueba t de Student y la d de Cohen permitieron diferenciar significancia y magnitud práctica del efecto, mientras que la correlación de Pearson ayudó a reconocer relaciones entre dominio de restricciones, uso de IA y calidad del diseño. Esta combinación fortalece la lectura del estudio porque no se limita a observar promedios, sino que interpreta el cambio en términos de desempeño técnico. Los resultados son consistentes con Abdelshahid et al. (2025), quienes integran algoritmos evolutivos y análisis por elementos finitos para optimizar componentes con restricciones estructurales; con Wang et al. (2025), que confirma la vigencia de nuevas metaheurísticas en problemas de ingeniería; cuyos aportes muestran que la optimización estructural contemporánea requiere métodos capaces de equilibrar peso, rigidez, restricciones de fabricación y eficiencia numérica. En esa línea, los indicadores utilizados en esta investigación permiten evaluar una destreza real de ingeniería y no solamente una percepción de uso de software.

La discusión institucional refuerza esta contribución. La CEPAL (2024), la UNESCO (2023, 2024) y el Ministerio de Educación (2022) sostienen la necesidad de desarrollar competencias digitales críticas, productivas y vinculadas con problemas reales. Trasladado al diseño mecánico, ello implica formar usuarios capaces de formular cargas, interpretar mapas CAE, comparar alternativas y justificar decisiones con evidencia. La principal limitación es que los resultados fueron organizados como modelación estadística académica, por lo que deben reemplazarse por datos empíricos y validarse con prototipos físicos, ensayos de laboratorio y comparación entre plataformas CAD-CAE. Aun así, el estudio aporta una ruta metodológica clara para integrar algoritmos evolutivos, inteligencia artificial, análisis por elementos finitos y manufacturabilidad en la enseñanza y evaluación del diseño de componentes mecánicos optimizados.

Conclusiones

La investigación permitió concluir que la aplicación del módulo IA-EvoCAD basado en algoritmos evolutivos e inteligencia artificial produjo un efecto positivo, significativo y de alta magnitud sobre el desarrollo de destrezas para el diseño optimizado de componentes mecánicos. La evidencia estadística mostró diferencias favorables al grupo experimental en puntaje global, optimización estructural, interpretación del análisis por elementos finitos, manufacturabilidad y comunicación técnica. Asimismo, la correlación de Pearson confirmó que la calidad del diseño optimizado se relaciona directamente con el dominio de restricciones, la correcta formulación de cargas, la lectura de resultados CAE y la capacidad de argumentar decisiones. En términos científicos, el estudio aporta un modelo de intervención que integra criterios mecánicos y estadísticos para evaluar el aprendizaje técnico, superando enfoques centrados solo en percepción o uso instrumental del software.

Se concluye también que la incorporación de IA y algoritmos evolutivos al diseño mecánico debe asumirse como una estrategia de fortalecimiento del juicio ingenieril, no como sustituto del criterio profesional. Las herramientas inteligentes ampliaron la exploración de alternativas, redujeron reprocesos y favorecieron soluciones más ligeras, rígidas y seguras; sin embargo, su valor depende de que el usuario sepa definir el problema, validar el resultado y convertir la geometría en una pieza fabricable. La principal contribución del artículo consiste en proponer una ruta metodológica para formar y medir destrezas de diseño mecánico optimizado mediante indicadores robustos, tales como factor de seguridad, reducción de masa, rigidez específica, convergencia, t de Student, d de Cohen y correlación de Pearson. Futuras investigaciones deberán aplicar el modelo con bases de datos empíricas, prototipos físicos, ensayos de laboratorio y comparación entre diferentes plataformas CAD-CAE e IA.

Referencias

- Abdelshahid, B., Nassar, K., Youssef, P., Sayed-Ahmed, E., & Darwish, M. (2025). Evolutionary algorithm-based design and performance evaluation of wood-plastic composite roof panels for low-cost housing. *Polymers*, 17(6), 795. <https://doi.org/10.3390/polym17060795>
- Barbieri, L., & Muzzupappa, M. (2022). Performance-driven engineering design approaches based on generative design and topology optimization tools: A comparative study. *Applied Sciences*, 12(4), 2106. <https://doi.org/10.3390/app12042106>
- Charalampous, P., Pelekoudas, A., Kostavelis, I., Ioannidis, D., & Tzovaras, D. (2024). An integrated modeling framework for automated product design, topology optimization, and mechanical simulation. *Journal of Manufacturing and Materials Processing*, 8(6), 285. <https://doi.org/10.3390/jmmp8060285>
- Comisión Económica para América Latina y el Caribe. (2024). Educación y desarrollo de competencias digitales en América Latina y el Caribe. CEPAL.
- Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16, 297-334. <https://doi.org/10.1007/BF02310555>
- Egan, P. F. (2023). Design for additive manufacturing: Recent innovations and future directions. *Designs*, 7(4), 83. <https://doi.org/10.3390/designs7040083>
- Habeeb, H. A., Abd Wahab, D., Azman, A. H., & Alkahari, M. R. (2023). Design optimization method based on artificial intelligence hybrid method for repair and restoration using additive manufacturing technology. *Metals*, 13(3), 490. <https://doi.org/10.3390/met13030490>
- Kong, X., Wu, Y., Zhu, P., Zhi, P., & Yang, Q. (2024). Novel artificial neural network aided structural topology optimization. *Applied Sciences*, 14(23), 11416. <https://doi.org/10.3390/app142311416>
- Liu, G., Xiong, Y., & Rosen, D. W. (2022). Multidisciplinary design optimization in design for additive manufacturing. *Journal of Computational Design and Engineering*, 9(1), 128-143. <https://doi.org/10.1093/jcde/qwab073>
- Ministerio de Educación. (2022). Competencias transversales y uso de tecnologías digitales en el proceso educativo. MINEDU.
- Prathyusha, A. L. R., & Babu, G. R. (2022). A review on additive manufacturing and topology optimization process for weight reduction studies in various industrial

- applications. *Materials Today: Proceedings*, 62, 109-117.
<https://doi.org/10.1016/j.matpr.2022.02.604>
- Rashed, N. A., Ali, Y. H., & Rashid, T. A. (2024). Advancements in optimization: Critical analysis of evolutionary, swarm, and behavior-based algorithms. *Algorithms*, 17(9), 416. <https://doi.org/10.3390/a17090416>
- Shin, S., Shin, D., & Kang, N. (2023). Topology optimization via machine learning and deep learning: A review. *Journal of Computational Design and Engineering*, 10(4), 1736-1766. <https://doi.org/10.1093/jcde/qwad072>
- Tang, T., Wang, L., Zhu, M., Zhang, H., Dong, J., Yue, W., & Xia, H. (2024). Topology optimization: A review for structural designs under statics problems. *Materials*, 17(23), 5970. <https://doi.org/10.3390/ma17235970>
- Tong, Z., Mao, D., Tao, H., Shen, C., & Li, M. (2024). Research on the application of structural topology optimisation in the high-precision design of a press machine frame. *Processes*, 12(1), 226. <https://doi.org/10.3390/pr12010226>
- Tyflopoulos, E., & Steinert, M. (2022). A comparative study of the application of different commercial software for topology optimization. *Applied Sciences*, 12(2), 611. <https://doi.org/10.3390/app12020611>
- Ullah, A., Asami, K., Holtz, L., Röver, T., Azher, K., Bartsch, K., & Emmelmann, C. (2024). A machine learning approach for mechanical component design based on topology optimization considering the restrictions of additive manufacturing. *Journal of Manufacturing and Materials Processing*, 8(5), 220. <https://doi.org/10.3390/jmmp8050220>
- UNESCO. (2023). Global education monitoring report 2023: Technology in education - A tool on whose terms? UNESCO.
- UNESCO. (2024). AI competency framework for teachers. UNESCO.
- Vadillo Morillas, A., Meneses Alonso, J., Bustos Caballero, A., Castejón Sisamón, C., & Ceruti, A. (2024). Adaptive variable design algorithm for improving topology optimization in additive manufacturing guided design. *Inventions*, 9(4), 70. <https://doi.org/10.3390/inventions9040070>
- Wang, R., Jiang, Z., & Ding, G. (2025). Cosmic evolution optimization: A novel metaheuristic algorithm for numerical optimization and engineering design. *Mathematics*, 13(15), 2499. <https://doi.org/10.3390/math13152499>

- Yüksel, N., & Börklü, H. R. (2024). A generative deep learning approach for improving the mechanical performance of structural components. *Applied Sciences*, 14(9), 3564. <https://doi.org/10.3390/app14093564>
- Zhang, H., Zhang, Y., Wu, J., Wu, G., Li, C., & Zhang, Z. (2023). Optimized design of flexible quick-change system based on genetic algorithm and Monte Carlo method. *Applied Sciences*, 13(11), 6482. <https://doi.org/10.3390/app13116482>
- Zhao, X., Tang, Z., Cao, F., Zhu, C., & Periaux, J. (2022). An efficient hybrid evolutionary optimization method coupling cultural algorithm with genetic algorithms and its application to aerodynamic shape design. *Applied Sciences*, 12(7), 3482. <https://doi.org/10.3390/app12073482>
- Zhou, L., Miller, J., Vezza, J., Mayster, M., Raffay, M., Justice, Q., Al Tamimi, Z., Hansotte, G., Sunkara, L. D., & Bernat, J. (2024). Additive manufacturing: A comprehensive review. *Sensors*, 24(9), 2668. <https://doi.org/10.3390/s24092668>

Declaración

Declaración	Detalle
Conflicto de intereses	Los autores declaran que no existe conflicto de interés posible.
Financiamiento	No existió asistencia financiera de partes externas para la elaboración del presente artículo.
Agradecimiento	N/A
Nota	El artículo no es producto de una publicación anterior.