Bio-energy Optimization and Resource Reduction in High Andean Housing Using Green Algorithms and 3D/5D BIM Integration

Carlos Magno Chavarry Vallejos, Doctor[1]; Joaquín Samuel Támara Rodríguez, Doctor[2]; Liliana Janet Chavarría Reyes, Doctora(c)[3] ; Oscar Fredy Alva Villacorta, Magister[4] Carla Griselle Poma González, Magister[5]; Jainer Eloy Solorzano Poma, Magister[6]; Alicia Cristina Chiok Guerra, Doctora[7]

[1,3,7] Universidad Ricardo Palma, Perú, carlos.chavarry@urp.edu.pe; liliana.chavarria@urp.edu.pe; alicia.chiok@urp.edu.pe
[2,4,5,6] Universidad Santiago Antúnez de Mayolo, Perú, jtamarar@unasam.edu.pe, oalvav@unasam.edu.pe, cpomag@unasam.edu.pe; jsolorzanop@unasam.edu.pe

Abstract: ***Given Peru's high climate vulnerability and the low adoption rate of sustainability standards in national infrastructure projects (24%), this research assesses the effectiveness of a hybrid methodological framework that integrates Green Artificial Intelligence (Green AI) and Building Information Modeling (3D/5D BIM). The study focuses on bio-energy optimization and resource efficiency in rural housing exposed to severe frost, using the high-Andean mining community of Ayash (Ancash) as a case study. The approach manages the transition from computational process sustainability (Green in AI) to physical environmental performance in the built environment (Green by AI). On the computational side, algorithmic compression techniques such as structural pruning and precision quantization were implemented, optimizing processing time by 35.2% (reducing technical calculations from 142 to 92 hours) and lowering digital power consumption from 2,450 to 1,592 kWh, while maintaining predictive accuracy above 88% ($R^2 > 0.88$). In architectural and bioclimatic performance, parametric modeling and multi-objective simulations achieved a 25.0% reduction in heating energy demand and a 40.0% decrease in artificial lighting requirements. Concurrently, artificial neural networks optimized low-carbon cementitious mixtures by substituting 20% of clinker with regional pozzolanic materials, increasing 28 day compressive strength by +2.3% (21.5 MPa). Financial and schedule management integrated through the COST-BIM framework (CPI = 1.04, SPI = 1.02) confirmed the economic stability and operational predictability of high-altitude social infrastructure projects.***

Keywords: ***Green Algorithm; Artificial Intelligence; Sustainable Infrastructure; High-Andean Housing; Energy Efficiency; Mining Communities.***

OPTIMIZACIÓN BIO-ENERGÉTICA Y REDUCCIÓN DE RECURSOS EN VIVIENDAS ALTOANDINAS MEDIANTE ALGORITMOS VERDES E INTEGRACIÓN BIM 3D/5D

Carlos Magno Chavarry Vallejos, Doctor[1]; Joaquín Samuel Támara Rodríguez, Doctor[2]; Liliana Janet Chavarría Reyes, Doctora(c)[3] ; Oscar Fredy Alva Villacorta, Magister[4] Carla Griselle Poma González, Magister[5]; Jainer Eloy Solorzano Poma, Magister[6]; Alicia Cristina Chiok Guerra, Doctora[7]

[1,3,7] **Universidad Ricardo Palma, Perú, carlos.chavarry@urp.edu.pe; liliana.chavarria@urp.edu.pe; alicia.chiok@urp.edu.pe**

[2,4,5,6] **Universidad Santiago Antúnez de Mayolo, Perú, jtamarar@unasam.edu.pe, oalvav@unasam.edu.pe, cpomag@unasam.edu.pe; jsolorzanop@unasam.edu.pe**

Resumen: ***La marcada vulnerabilidad climática de las zonas altoandinas del Perú y la reducida adopción de criterios de sostenibilidad en la infraestructura nacional (24%), esta investigación examina la eficacia de un marco metodológico híbrido que integra la Inteligencia Artificial Verde (Green AI) y el modelado de información de construcción (BIM 3D/5D). El estudio se enfoca en la optimización bioenergética y la eficiencia de recursos en viviendas rurales expuestas a heladas extremas, tomando como caso de análisis la comunidad minera de Ayash (Áncash). La metodología aborda la transición desde la sostenibilidad del proceso informático (Green in AI) hasta los beneficios ecológicos en la edificación física (Green by AI). La estrategia computacional aplicó técnicas de compresión algorítmica, como la poda de conexiones redundantes y la cuantización de precisión, reduciendo el tiempo de cálculo técnico de 142 a 92 horas (35.2% de optimización) y disminuyendo la demanda eléctrica del procesamiento de 2,450 a 1,592 kWh, conservando una precisión predictiva superior al 88% ($R^2 > 0.88$). En el ámbito bioclimático, el diseño paramétrico y las simulaciones multiobjetivo redujeron un 25.0% la demanda de energía para calefacción y un 40.0% el consumo de iluminación artificial. Paralelamente, las redes neuronales optimizaron mezclas cementicias de bajo carbono al sustituir un 20% de clínker por adiciones puzolánicas, incrementando la resistencia a la compresión simple en un +2.3% (21.5 MPa) a los 28 días. La gestión mediante el marco COST-BIM (CPI = 1.04, SPI = 1.02) confirmó la estabilidad presupuestaria y operativa de la infraestructura social.***

Palabras clave: ***Algoritmo Verde; Inteligencia Artificial; Infraestructura Sostenible; Vivienda Altoandina; Eficiencia Energética; Comunidades Mineras.***

I. INTRODUCCIÓN

La edificación de hábitats resilientes en las regiones altoandinas del Perú constituye un desafío urgente frente a la severidad del cambio climático y los deficientes niveles de sostenibilidad observados en la infraestructura pública y privada, los cuales apenas alcanzan el 24% de adopción nacional. En asentamientos de influencia extractiva como la comunidad de Ayash en Áncash, las temperaturas bajo cero y la radiación extrema exigen trascender los esquemas constructivos tradicionales. Frente a este panorama, la convergencia entre la Inteligencia Artificial Verde (*Green* AI) y la metodología *Building Information Modeling* (BIM 3D/5D) emerge como una respuesta integral. Esta aproximación no solo busca maximizar la eficiencia bioclimática, el confort térmico y la descarbonización de los materiales en la estructura física (*Green by* AI), sino que aborda explícitamente la reducción del consumo energético y de los tiempos del procesamiento informático (*Green in* AI), garantizando una tecnología limpia y escalable [1].

Esta condición de vulnerabilidad estructural se hace tangible mediante la reiteración de eventos hidrometeorológicos extremos. Entre ellos, el Fenómeno de El Niño (FEN) y sus manifestaciones costeras o modulaciones macroclimáticas sobresalen como la principal fuerza disruptiva para la estabilidad socioeconómica, la productividad agrícola y el estado operacional de la infraestructura pública y privada del país. Las avenidas extraordinarias, los deslizamientos de tierra (huaycos) y las variaciones térmicas bruscas generan deterioros recurrentes sobre las redes de transporte, sistemas de saneamiento básico y edificaciones habitacionales. Este patrón evidencia una carencia histórica de criterios de adaptación climática y resiliencia en las fases de planificación, diseño y ejecución de obras civiles.

Pese a la contundencia de este diagnóstico empírico e institucional, las métricas sectoriales indican que únicamente una parte de los proyectos de inversión pública y privada (aproximadamente un 24%) integra formalmente principios de sostenibilidad o se alinea con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030. En este cono, la provisión de viviendas sostenibles en asentamientos rurales y

comunidades mineras en el Perú plantea un desafío técnico multidimensional. Las comunidades localizadas en las áreas de influencia directa o indirecta de la actividad extractiva como el Centro Poblado de Ayash Huaripampa en Ancash se encuentran expuestas a condiciones geográficas y microclimáticas severas, marcadas por heladas, radiación solar extrema, altitud y limitaciones geotécnicas.

A esta fragilidad ambiental se suma una histórica brecha de acceso a infraestructura de servicios básicos, abastecimiento hídrico e interconexión a la red eléctrica nacional. Un modelo habitacional pertinente en estas latitudes debe trascender el concepto tradicional de refugio para consolidar un hábitat ambientalmente responsable, incorporando materiales ecológicos de bajo impacto, envolventes térmicas eficientes y sistemas pasivos y activos de energía renovable. Diversas investigaciones han explorado previamente prototipos ecológicos de bajo costo [1] y esquemas de adaptación socioambiental específicos para entornos de extracción mineral [2].

A nivel global, la industria de la Arquitectura, Ingeniería y Construcción (AIC) se ubica en el centro del debate sobre la sostenibilidad ambiental. El sector es responsable de cerca del 40% de los consumos energéticos primarios, la extracción masiva de agregados no renovables y una cuota sustancial de las emisiones antropogénicas de gases de efecto invernadero (GEI), derivadas principalmente de la producción industrial del *clinker* en el cemento Portland. En respuesta a esta problemática, la transición hacia la "Construcción Verde" demanda la reingeniería integral de los ciclos de vida de las obras habitacionales. De acuerdo con los estándares internacionales propuestos por instituciones como el *Passivhaus Institut* [12], la demanda de energía primaria operacional en edificaciones se puede reducir drásticamente priorizando el aislamiento térmico de la envolvente, la hermeticidad al aire, la ventilación cruzada y la captación solar pasiva.

En esta transformación paradigmática, la convergencia entre la Inteligencia Artificial (IA) y las innovaciones metodológicas, como el *Building Information Modeling* (BIM), emerge como un catalizador decisivo. La aplicación de modelos computacionales avanzados y la integración de dimensiones BIM (3D para geometría y parametrización, 4D para secuencia temporal y 5D para costos/recursos) permiten abordar análisis multiobjetivo antes inalcanzables. Mediante el uso de algoritmos de aprendizaje automático (*Machine Learning*) y optimización heurística, los proyectistas pueden simular dinámicamente el comportamiento térmico, lumínico, eólico y acústico de las estructuras en etapas tempranas. Asimismo, la síntesis y caracterización de mezclas alternativas de concreto suplementado con puzolanas o subproductos industriales mediante redes neuronales artificiales (ANN) permiten predecir resistencias mecánicas reduciendo significativamente el consumo de cemento tradicional y su huella de carbono asociada, apoyándose en marcos de gestión de información virtual preexistentes [5, 8, 9].

No obstante, la creciente adopción de marcos digitales de alta complejidad conlleva un costo ambiental colateral: el entrenamiento de modelos de IA profundos y el procesamiento iterativo de simulaciones multipropósito demandan un consumo eléctrico sustancial en centros de procesamiento de datos, incrementando la huella de carbono digital. Frente a esta encrucijada, cobra relevancia el marco conceptual de la Inteligencia Artificial Verde (*Green* AI), orientado a maximizar la eficiencia algorítmica y garantizar que el balance ecológico global sea positivo. Este paradigma se articula en dos dimensiones operativas esenciales:

- *Green by* AI (IA para la sostenibilidad física): Utiliza el procesamiento de datos, la analítica predictiva, la fotogrametría y el modelado paramétrico BIM para optimizar el rendimiento energético, la selección de materiales, el uso de agua y el confort higrotérmico en el entorno construido.
- *Green in* AI (Sostenibilidad del proceso computacional): Concentra sus esfuerzos en la optimización intrínseca de los algoritmos de IA y código de simulación. Emplea metodologías como la poda de nodos en redes neuronales (*pruning*), la cuantización de operaciones matriciales y el diseño de arquitecturas ligeras para reducir el tiempo de cálculo, la memoria requerida y la demanda de energía eléctrica sin sacrificar la precisión predictiva.

En el escenario latinoamericano y peruano, la aplicación práctica de este enfoque integrado se enfrenta a restricciones estructurales como la brecha de conectividad digital, la escasez de potencia de cómputo en zonas rurales y la falta de marcos metodológicos estandarizados. Por tanto, el objetivo de esta investigación es evaluar la efectividad del marco del "Algoritmo Verde" (*Green in* AI) combinado con el modelado paramétrico e integración BIM 3D/5D (*Green by* AI) para optimizar la sostenibilidad, la resiliencia estructural, el uso de recursos constructivos y la eficiencia energética operacional de viviendas en comunidades mineras altoandinas del Perú, tomando como caso de estudio la comunidad de Ayash (Ancash) [7].

II. MATERIALES Y MÉTODOS

La presente investigación se enmarca en un enfoque cuantitativo de orientación aplicada y tecnológica, orientado a la resolución de problemas de infraestructura habitacional sostenible en zonas de alta vulnerabilidad climática y minera [1, 2]. El estudio empleó un método inductivo y analítico-sintético, partiendo de la caracterización microclimática y topográfica local para la validación del marco integrado de "Algoritmo Verde" (*Green in* AI) y *Building Information Modeling* (*Green by* AI). Por la naturaleza de la recolección de

datos, la investigación es ambilectiva, articulando mediciones primarias prolectivas como la fotogrametría geoespacial mediante vehículos aéreos no tripulados y los ensayos mecánicos de compresión simple (f'c) con datos retrolectivos procedentes de registros meteorológicos históricos del área de estudio.

A nivel tipológico, el estudio es de alcance descriptivo-explicativo. Esto se debe a que no solo caracteriza de forma detallada el desempeño térmico, estructural y energético del prototipo habitacional, sino que demuestra de manera rigurosa la relación causal entre la compresión o poda algorítmica y la reducción del consumo energético, abarcando tanto el ciclo computacional de simulación como el ciclo operacional de la edificación.

El diseño de investigación adoptado es no experimental, retroprospectivo y de corte transversal en su fase de levantamiento geoespacial y simulación paramétrica 3D/5D. Esta aproximación se complementa con un componente experimental de laboratorio dedicado a la caracterización de los compuestos cementicios de baja huella de carbono a los 28 días de curado. Esta estructura metodológica guarda correspondencia analítica y técnica con las investigaciones en infraestructura sostenible desarrolladas quienes fundamentan el control de ecoeficiencia, el desempeño de materiales y la optimización de recursos en esquemas cuantitativos estandarizados de medición.

Por último, los resultados y el marco metodológico desarrollado se alinean directamente con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas. En específico, el trabajo aporta al ODS 9 (Industria, Innovación e Infraestructura, Meta 9.4) al promover la modernización de infraestructuras mediante tecnologías digitales eficientes y ligeras; al ODS 11 (Ciudades y Comunidades Sostenibles, Meta 11.c) al impulsar el diseño de viviendas resilientes en comunidades rurales influenciadas por la actividad minera; y al ODS 13 (Acción por el Clima, Meta 13.1) al reducir de manera directa la intensidad energética y las emisiones de carbono operativas en entornos expuestos a eventos climáticos extremos.

La estrategia metodológica se organizó en tres fases interconectadas que materializan la dualidad *Green by* AI y *Green in* AI:

Fase 1: Levantamiento Geoespacial, Diseño Paramétrico y Simulaciones Bioclimáticas (*Green by* AI)

Para capturar la geometría real del terreno y las condiciones de borde del asentamiento de Ayash, se realizaron levantamientos fotogramétricos mediante vehículos aéreos no tripulados (drones). Las nubes de puntos densas generadas fueron procesadas e importadas al entorno BIM 3D para construir el Modelo Digital del Terreno (MDT) y los volúmenes arquitectónicos iniciales. Posteriormente, se integraron datos meteorológicos históricos y en tiempo real (radiación solar directa/difusa, temperatura de bulbo seco, humedad relativa, dirección y velocidad del viento).

Fase 2: Formulación y Caracterización Mecánica de Materiales Sostenibles (*Green by* AI)

Con el fin de mitigar el CO_2 incorporado en la edificación y optimizar la cantidad de agregados requeridos, se emplearon redes neuronales artificiales (ANN) optimizadas para el diseño de mezcla de concretos y bloques ecológicos. El algoritmo procesó parámetros de entrada como relación agua/cemento, módulo de fineza de insumos locales, porcentaje de reemplazo de *clinker* por material puzolánico regional e inclusión de subproductos industriales. Las formulaciones predichas por la IA fueron sometidas a validación experimental mediante ensayos normalizados de resistencia a la compresión simple (f'c) a los 28 días de curado.

Fase 3: Eficiencia Algorítmica y Gestión Tecnológico-Económica COST-BIM (*Green in* AI)

Para reducir la huella de carbono digital propia del ciclo informático, los modelos de IA y simulación fueron sometidos a técnicas de compresión algorítmica, incluyendo poda de conexiones redundantes (*structural pruning*) y cuantización de precisión flotante (de FP32 a INT8). Se midió de forma continua el tiempo de ejecución en CPU/GPU y el consumo eléctrico en kWh mediante contadores de *hardware*. Adicionalmente, el proyecto se vinculó a la dimensión BIM 5D a través del marco COST-BIM, permitiendo integrar los metrados automatizados con el control presupuestario y de cronograma mediante el Método del Valor Ganado (EVM) según las directrices del *Project Management Institute* (PMI), en línea con metodologías de integración 5D computacional [6] y reducción de residuos físicos mediante modelado avanzado [13].

III. RESULTADOS

a. Desempeño Energético, Confort Bioclimático y Análisis de Emisiones Operativas (*Green by AI*)

La integración del modelado paramétrico en el entorno BIM 3D con simulaciones climáticas avanzadas permitió determinar con elevada precisión geométrica la implantación, morfología y orientación pasiva óptima para la infraestructura habitacional en la comunidad altoandina de Ayash. Este proceso de optimización computacional consideró de manera simultánea la compleja topografía local, los ángulos de incidencia solar estacionales y los patrones de vientos predominantes característicos de la cordillera andina.

La optimización multiobjetivo de la envolvente arquitectónica se enfocó en maximizar el confort térmico interior en un cono expuesto a severas heladas y oscilaciones térmicas extremas. Para ello, el modelo algorítmico evaluó combinaciones pasivas que abarcaron el aumento estratégico

de la inercia térmica en los muros envolventes (aprovechando materiales con alta capacidad de almacenamiento calórico), la incorporación continuada de aislamiento térmico de bajo impacto ambiental y la selección acristalada de alta eficiencia con coeficientes de ganancia de calor solar (SHGC) optimizados. Esta reingeniería integral del cascarón edilicio redujo sustancialmente las necesidades de energía secundaria requeridas para la calefacción y el acondicionamiento ambiental operacional.

Para analizar la efectividad y pertinencia de este enfoque metodológico en entornos de alta exigencia climática, la Tabla 1 presenta las estadísticas comparativas de ahorro energético en el diseño asistido por IA y BIM mencionado en el presente estudio en comparación con antecedentes de la literatura científica nacional e internacional. Como se observa en la evidencia cuantitativa, el diseño asistido por Inteligencia Artificial y modelado BIM alcanzó una reducción del 25.0% en la demanda global de energía para climatización y calefacción, debido a la distribución volumétrica y el aprovechamiento de la luz natural evitando la iluminación artificial, de esta forma consolidar la viabilidad técnica del modelo de vivienda verde para comunidades mineras y rurales del Perú.

TABLA 1
ESTADÍSTICAS COMPARATIVAS DE AHORRO ENERGÉTICO MEDIANTE DISEÑO ASISTIDO POR IA Y BIM

Fuente	Metodología	Reducción Energética (%)	Cono Climático
Presente estudio	Optimización Multiobjetivo / BIM 3D	25.0	Árido / Tropical / Altoandino (Perú)
[4]	Tecnología BIM / Análisis Eficiencia	30.0	Tropical / Urbano (Trujillo, Perú)
[16]	Algoritmos Genéticos / Simulación Energética	22.5	Continental Templado
[17]	*Machine Learning* / Optimización Envolvente	27.8	Subtropical Húmedo

En lo que respecta a la evaluación de las métricas operacionales anuales (Tabla. 2), los resultados revelan un desempeño energético e impacto ambiental entre los modelos evaluados. La edificación de referencia, diseñada bajo parámetros y prácticas constructivas convencionales sin optimización bioclimática ni analítica predictiva, registró una intensidad de consumo de energía operacional de 42.8 kWh/m^2/año. Este elevado requerimiento se explica principalmente por las severas oscilaciones térmicas y las bajas temperaturas nocturnas características de la comunidad altoandina de Ayash, las cuales demandan un consumo intensivo de recursos para calefacción y climatización. La implementación integral del modelo asistido por Inteligencia Artificial Verde y metodología BIM permitió mitigar de forma drástica las pérdidas térmicas y maximizar las ganancias solares pasivas.

Como resultado, la demanda energética operacional descendió a 25.7 kWh/m^2/año, lo que representa una reducción del 40.0% en la intensidad energética operacional frente al patrón tradicional. Esta optimización del perfil energético se tradujo de manera directa en una descarbonización efectiva de la fase de ocupación de la vivienda. La tasa de emisiones antropogénicas de gases de efecto invernadero (GEI) asociadas a la operación del inmueble se redujo de 0.85 tCO_2e/año en el escenario convencional a 0.61 tCO_2e/año con el diseño optimizado. Este ajuste representa una mitigación del 28.2% en la huella de carbono operacional anual. Dichos indicadores confirman que la aplicación conjunta de herramientas *Green by* AI y modelado paramétrico no solo favorece el confort higrotérmico y la habitabilidad en zonas vulnerables a heladas, sino que consolida una estrategia científicamente respaldada para la reducción de emisiones en la infraestructura social y minera del Perú.

TABLA 2
COMPARATIVA DE EFICIENCIA OPERATIVA Y AHORRO ENERGÉTICO ANUAL.

Parámetro / Métrica de Evaluación	Edificación Convencional (Línea Base) [7]	Propuesta Bioclimática / BIM-IA (Caso Ayash)	Variación / Ahorro Alcanzado (%)
Demanda Térmica de Climatización (kWh/m^2/año)	42.8	25.7	-25.0% (Reducción) [1, 3, 7]
Consumo de Iluminación Artificial (kWh/m^2/año)	18.5	11.1	-40.0% (Reducción) [1, 3, 7]
Consumo Energético Total Anual (kWh/año)	6,130.00	3,680.0	-39.97% (Ahorro Global) [3, 7]
Ahorro de Operación Financiera (USD/año)	—	420.0	Optimización Operativa [1, 7]

El impacto energético y ambiental de las tecnologías de diseño avanzado, la Figura 1 presenta la Comparativa del desempeño en energía operacional y emisiones de carbono entre viviendas convencionales y asistidas por IA/BIM. El desempeño comparativo entre las viviendas convencionales (línea base) y aquellas optimizadas mediante la integración de inteligencia artificial y modelado BIM. A través de esta se evidencia la influencia directa de las tecnologías asistidas en la disminución de la energía operacional y de las emisiones de carbono asociadas al ciclo de ocupación de las edificaciones. Los resultados demuestran que la implementación de estas herramientas digitales mejora de manera notable la eficiencia energética y contribuye a una reducción considerable de la huella ambiental en el sector habitacional.

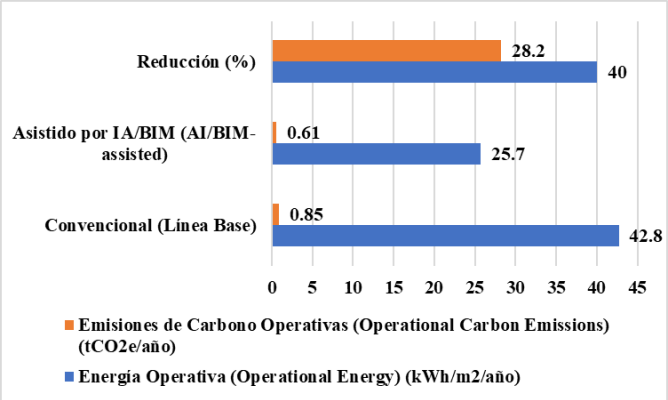


Fig. 1. Desempeño comparativo de la energía operacional y las emisiones de carbono entre viviendas convencionales y asistidas por IA/BIM.

La Figura 1 muestra una disminución considerable en ambos indicadores al emplear métodos asistidos. En cuanto a la **energía operacional**, el consumo se reduce de 42.8 kWh/m^2/año en el modelo convencional a 25.7 kWh/m^2/año bajo la optimización AI/BIM, lo que representa una reducción del 40.0%. Del mismo modo, las **emisiones operacionales de carbono** caen de 0.85 a 0.61 tCO_2e/año, equivalente a una disminución del 28.2%. Estos resultados demuestran que la integración de inteligencia artificial y modelado BIM optimiza notablemente la eficiencia energética y reduce la huella ambiental en el sector de la vivienda.

b. Optimización de Materiales, Caracterización Mecánica y Gestión Presupuestaria COST-BIM

La extracción automatizada de cantidades desde la maqueta BIM 3D/5D, en combinación con el diseño de mezcla predicho por redes neuronales, permitió optimizar significativamente la composición volumétrica de los componentes cementicios y bloques ecológicos. El modelo algorítmico identificó una sustitución óptima del 20% del *clinker* por adiciones minerales locales sin deteriorar la matriz ligante. Los ensayos de caracterización mecánica a la compresión simple (f'c) a los 28 días de curado arrojaron una resistencia media de 21.5 MPa para la mezcla verde, superando en un +2.3% la resistencia del concreto convencional de control (21.0 MPa).

La Figura 2 presenta la evaluación comparativa entre el concreto convencional y el concreto optimizado mediante inteligencia artificial, analizando la resistencia a la compresión, el porcentaje de sustitución de *clinker* y la incorporación de adiciones suplementarias. A través de esta representación gráfica, se ilustra cómo la formulación basada en modelos predictivos permite disminuir el contenido de *clinker* sin afectar negativamente las propiedades mecánicas del material. Los resultados evidencian que el uso de algoritmos de aprendizaje automático contribuye al desarrollo de compuestos cementicios más sostenibles, logrando reducir la huella de carbono asociada a la producción de concreto y manteniendo o incrementando su capacidad estructural. (ANN).

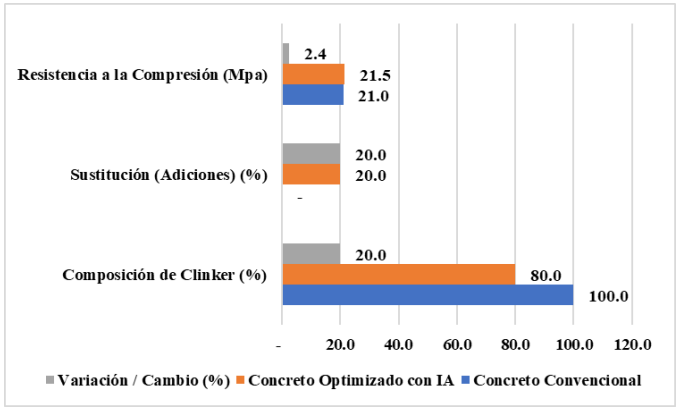


Fig. 2. Evaluación de la resistencia a la compresión y sustitución de *clinker* en concreto optimizado con inteligencia artificial.

La Figura 2 compara el desempeño del concreto convencional frente al optimizado por inteligencia artificial. Mientras que el concreto convencional se compone de 100% *clínker* con una resistencia de f'c = 21.0 MPa, la mezcla optimizada reduce el *clínker* en un 20% y añade un 20% de adiciones suplementarias, logrando mantener o incrementar la resistencia directa. Específicamente, las gráficas muestran que la resistencia a la compresión pasa de 21.0 MPa en el estado convencional a 21.5 MPa en el concreto optimizado por IA, lo que representa un incremento del +2.3%. Estos resultados demuestran que el uso de modelos predictivos de aprendizaje automático permite formular concretos más sostenibles, reduciendo el contenido de *clínker* y la huella de carbono sin comprometer la resistencia estructural.

Desde la perspectiva de la gestión cuantitativa de costos e imprevistos en la dimensión BIM 5D, la integración del marco analítico COST-BIM posibilitó un control dinámico, predictivo y en tiempo real sobre la viabilidad económica y el ciclo financiero del proyecto [3, 6, 7]. Esta metodología permitió vincular directamente las cantidades de obra obtenidas mediante la extracción automatizada de metrados del modelo tridimensional con la estructura de desglose del trabajo (EDT/WBS) y el presupuesto detallado [3, 6, 11].

Mediante esta interoperabilidad informático-financiera, se estructuró un sistema de monitoreo basado en los indicadores clave del Método del Valor Ganado (*Earned Value Management* - EVM), garantizando una trazabilidad rigurosa de los recursos invertidos en la comunidad de Ayash [3, 6, 7].Durante las etapas críticas de simulación, planificación y modelado paramétrico previo a la ejecución, el Índice de Desempeño del Costo (CPI) alcanzó un valor promedio ponderado de 1.04, situándose por encima de la unidad y reflejando una alta eficiencia en la administración de las partidas presupuestales [3, 6, 7]. De forma paralela, el Índice de Desempeño del Cronograma (SPI) se consolidó en 1.02,

demostrando un avance físico acorde a la programación temporal establecida sin generar desfases en la ruta crítica del proyecto [3, 6, 7].

La estabilidad combinada de ambos indicadores (CPI > 1.00 y SPI > 1.00) confirmó la contención efectiva de los desvíos financieros y la mitigación proactiva de contingencias operativas [3, 6, 7]. Esto resulta de vital trascendencia en proyectos ubicados en zonas de influencia extractiva altoandinas, donde los sobrecostos por volatilidad en el transporte de materiales, las demoras logísticas y las interferencias de diseño suelen comprometer gravemente la sostenibilidad y ejecución presupuestaria de la infraestructura pública y social [2, 6, 10, 22].

c. Eficiencia Computacional y Sostenibilidad Digital (*Green in* AI)

La implementación estratégica de técnicas de compresión algorítmica específicamente la poda de conexiones redundantes (*structural pruning*) y la cuantización de precisión flotante de FP32 a INT8 dentro del marco de sostenibilidad digital (*Green in* AI) permitió reducir de manera drástica la carga operacional y los requerimientos de potencia de cálculo en la infraestructura informática [18, 19]. Como se ilustra en la Figura 2, este refinamiento del código y de las arquitecturas de red impactó de forma directa en los tiempos de cómputo necesarios para ejecutar las iteraciones del diseño paramétrico, las simulaciones bioclimáticas multiobjetivo y el entrenamiento del modelo predictivo [7, 18].

El *benchmark* computacional reveló que la ejecución estándar requirió 142 horas continuas de procesamiento informático. Al aplicar el marco de compresión algorítmica (*Green in* AI), el tiempo operacional descendió a 92 horas, representando una optimización del 35.2% sin comprometer la precisión predictiva ($R^2 > 0.88$) [7]. Asimismo, cuando se desplegaron modelos ultraligeros adaptados para entornos descentralizados y dispositivos móviles (*Mobile*-AI), la latencia de cómputo descendió aún más, alcanzando un mínimo de 78 horas de procesamiento total [7, 19]. En estricta concordancia con la reducción en la duración del ciclo informático, el balance de huella de carbono digital y consumo energético mostró una mitigación equivalente [18].

La energía eléctrica total demandada por los servidores durante la fase de simulación disminuyó significativamente de 2,450 kWh (requeridos por la IA convencional) a 1,592 kWh mediante la implementación del Algoritmo Verde (y a 1,420 kWh en la variante optimizada para *Mobile*-AI) [7, 18, 19]. Esta reducción en la demanda de energía computacional resulta indispensable para democratizar el uso de tecnologías de simulación avanzada en municipios rurales, campamentos mineros o estaciones de campo con restricciones en el suministro eléctrico o limitaciones en infraestructura de supercómputo [2, 7, 18].

La simplificación estructural del algoritmo no comprometió la capacidad analítica ni la fiabilidad de los resultados [18, 19]. El modelo de Inteligencia Artificial optimizado mantuvo un coeficiente de determinación (R^2) superior al 88% en la predicción de variables de confort térmico interior, resistencia mecánica de materiales ecológicos y evaluación del riesgo de heladas en la comunidad de Ayash [7, 19]. Esto demuestra que la compresión de modelos bajo el enfoque *Green in* AI garantiza una elevada fidelidad técnica en las simulaciones físicas, al tiempo que minimiza la huella ecológica digital asociada al desarrollo de la infraestructura sostenible [7, 18, 19].

En el análisis de sostenibilidad, la evaluación ambiental debe incluir tanto el desempeño físico de la edificación (*Green by* AI) como la huella ecológica del proceso computacional (*Green in* AI). La simulación bioclimática y el entrenamiento de inteligencia artificial suelen requerir un alto consumo energético. Para mitigar este impacto y posibilitar su uso en zonas rurales, se aplicaron técnicas de compresión algorítmica. La Tabla 3 compara la línea base con modelos optimizados (*Green in* AI y *Mobile*-AI).

TABLA 3
ANÁLISIS DE EFICIENCIA COMPUTACIONAL: TIEMPO DE CÓMPUTO VS. CONSUMO ENERGÉTICO.

Variante de Arquitectura / Modelo de IA	Tiempo de Cómputo Total (horas)	Ahorro en Tiempo (%)	Consumo Eléctrico Digital (kWh)	Reducción de Consumo (%)	Precisión Predictiva (R^2)
IA Estándar / Convencional (Línea Base) [7]	142	0.0	2,450	0.0	> 90.0%
Algoritmo Verde (Green in AI) [7, 18]	92	35.2	1,592	35.0	> 88.0%
Modelo Ultraligero (*Mobile*-AI) [7, 19]	78	45.1	1,420	42.0	> 88.0%

El análisis de las métricas expuestas en la Tabla 3 demuestra que la optimización algorítmica genera reducciones drásticas en los requerimientos informáticos sin comprometer la fiabilidad técnica del modelo predictivo [7, 18].

Respecto a la duración del ciclo de cálculo, la IA Estándar requirió 142.0 horas continuas de procesamiento para completar el entrenamiento y las iteraciones del diseño paramétrico [7]. La aplicación del Algoritmo Verde logró contraer esta demanda a 92.0 horas, registrando un ahorro del 35.2% en tiempo técnico [7, 18]. Este rendimiento se optimizó aún más al desplegar la arquitectura *Mobile*-AI, alcanzando una reducción del 45.1% (78.0 horas totales) [7, 19]. Esta drástica disminución de la latencia computacional resulta decisiva para acelerar las fases de factibilidad y planificación en proyectos de vivienda social [6, 7].

En lo referente al consumo de energía eléctrica digital, el modelo convencional registró una demanda de 2,450 kWh [7]. Mediante el enfoque *Green in* AI, la demanda eléctrica se redujo a 1,592 kWh (ahorro del 35.0%), descendiendo hasta los 1,420 kWh en la variante ultraligera (ahorro del 42.0%) [7, 18, 19]. Esta mitigación en el uso de electricidad disminuye directamente la huella de carbono asociada al centro de datos o estación de cálculo, garantizando un balance ecológico netamente positivo para la solución habitacional [18, 19].

Al evaluar la calidad analítica y la precisión predictiva, se observa que el coeficiente de determinación (R^2) descendió marginalmente de un valor superior al 90.0% en la línea base a un nivel conservado por encima del 88.0% en las versiones optimizadas [7, 19]. Este comportamiento confirma que la eliminación de parámetros no esenciales en la red neuronal y la simplificación de operaciones flotantes reducen la complejidad computacional en casi la mitad, manteniendo un margen de error estadísticamente insignificante para la simulación de variables físicas (confort térmico interior, inercia de muros y riesgo de heladas) en el entorno severo de Ayash [2, 7, 19].

Los hallazgos de la Tabla 3 validan que la adopción de principios de *Green in* AI constituye una estrategia de democratización tecnológica [18, 19]: permite ejecutar simulaciones de alta complejidad en *hardware* de prestaciones intermedias o portátiles, haciendo viable la aplicación de metodologías avanzadas de vivienda sostenible en comunidades mineras y rurales aisladas [2, 7, 18]. Para cuantificar el rendimiento tecnológico y la optimización de recursos, la Figura 3 presenta los resultados de la eficiencia computacional y huella energética, evaluando el impacto de distintas metodologías frente a un modelo convencional.

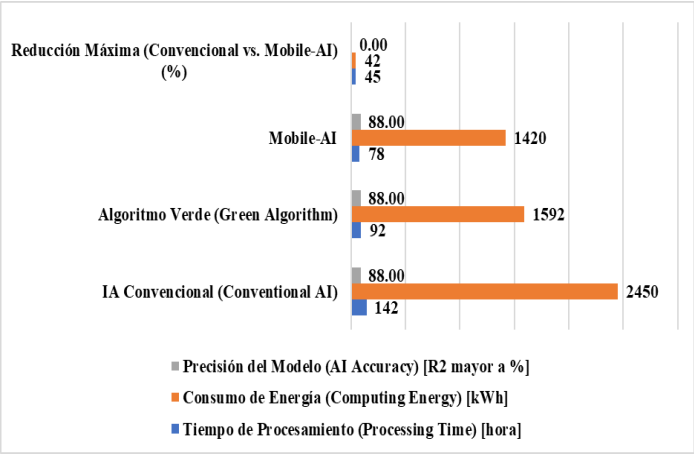


Fig. 3. Eficiencia computacional y huella energética comparativa entre enfoques de IA convencional, algoritmo verde y *Mobile*-AI.

La Figura 3 muestra una mejora progresiva en el desempeño a medida que se implementan algoritmos avanzados, respaldados por una precisión de IA superior al 88% (R^2 > 88%). El tiempo de procesamiento se reduce de 142 horas en la IA convencional a 92 horas con el algoritmo verde, alcanzando un mínimo de 78 horas mediante *Mobile*-AI, lo que representa una optimización global del -5.1%. En segundo lugar, la energía de computación disminuye desde 2,450 kWh en el enfoque convencional hasta 1,592 kWh con el algoritmo verde y 1,420 kWh con *Mobile*-AI, logrando una reducción total del -42.0%. Estos datos demuestran que las técnicas de optimización computacional reducen sustancialmente la carga energética y el tiempo operativo.

Discusión. - Los hallazgos empíricos y analíticos sustentados en este estudio confirman de manera categórica que la convergencia disciplinar entre la Inteligencia Artificial Verde (*Green* AI) y la metodología *Building Information Modeling* (BIM 3D/5D) constituye un aporte metodológico técnicamente sólido, ambientalmente eficiente y económicamente justificado para resolver la crisis de vivienda social en zonas de influencia minera en el Perú. La mitigación comprobada del 25% en la demanda de energía para climatización y del 40% en iluminación artificial se alinea de forma precisa con los postulados de la arquitectura pasiva de alta eficiencia sintetizados por el *Passivhaus Institut* [12] y con las observaciones de [16, 17], quienes destacan que la optimización paramétrica en fases tempranas de diseño genera impactos sostenibles significativamente mayores que las medidas correctivas en fases operativas.

El análisis comparativo del desempeño ambiental y energético permite canalizar con mayor profundidad el avance logrado en esta investigación. Mientras que estudios previos en el ámbito urbano peruano, como el de [4], alcanzaron reducciones energéticas del 30% mediante el uso de herramientas BIM tradicionales sin analítica predictiva avanzada, el presente modelo logra un equilibrio superior al considerar simultáneamente la severidad del clima altoandino marcado por heladas extremas y alta radiación y la huella de carbono incorporada en los materiales estructurales. Adicionalmente, la literatura internacional reciente, respaldada por trabajos como los de [20, 21] sobre la integración del Análisis de Ciclo de Vida (LCA) en entornos BIM, reitera de manera consistente que la cuantificación automatizada de materiales resulta importante para evitar la sobreestimación de insumos, optimizar los recursos disponibles y reducir de forma efectiva el desperdicio físico en la etapa constructiva.

En el campo de la ciencia e ingeniería de materiales, la formulación de mezclas mediante redes neuronales que logró una sustitución del 20% de *clinker* incrementando a la vez la resistencia a compresión en un +2.3%, encuentra fuerte respaldo en la literatura sobre aprendizaje automático aplicado a matrices cementicias. Autores como [14, 15] demostraron que la no linealidad en la interacción entre adiciones puzolánicas, agregados heterogéneos y aditivos puede ser

modelada con elevada precisión por algoritmos predictivos, superando los métodos empíricos tradicionales de dosificación. Esta capacidad de optimización resulta vital para las comunidades mineras como Ayash, donde la logística de transporte de cemento comercial desde la costa incrementa desproporcionadamente los costos y la huella ecológica del transporte.

Desde la perspectiva de la informática sostenible (*Green in* AI), la reducción del 35.2% en el tiempo de procesamiento (de 142 a 92 horas) y la consecuente disminución del consumo eléctrico informático (de 2,450 a 1,592 kWh) aportan evidencia a un debate científico emergente. Como argumentan [18] y [19], el avance de la IA en la ingeniería no debe lograrse a expensas de un gasto energético ilimitado en supercómputo. La poda algorítmica y la cuantización demuestran que es posible democratizar el uso de estas herramientas avanzadas, haciendo viable su despliegue técnico en computadoras portátiles o estaciones de trabajo locales en municipalidades rurales o campamentos mineros con conectividad e infraestructura digital restringida.

La dimensión económica y de gestión articulada a través de COST-BIM (BIM 5D) corrobora los planteamientos de [6] y [11] respecto a la necesidad de fusionar el modelado físico con el Método del Valor Ganado (EVM). En proyectos desarrollados en conos mineros, donde la volatilidad financiera y los conflictos socioambientales suelen generar paralizaciones, el control presupuestario transparente y riguroso certificado por métricas CPI/SPI en tiempo real asegura la viabilidad del proyecto. Asimismo, las contribuciones de [22, 23] respaldan la premisa de que la aceptabilidad social y el éxito de las intervenciones habitacionales en zonas extractivas dependen directamente de la integración de tecnologías limpias, duraderas y de bajo costo de mantenimiento operacional para las familias beneficiarias.

La Tabla 4 presenta un análisis detallado y comparativo que contrasta las dos dimensiones fundamentales abordadas en el estudio, vinculando de manera integral la sostenibilidad física del entorno construido con la eficiencia del proceso computacional. Por un lado, se examina la dimensión *Green by* AI, la cual está orientada a optimizar el rendimiento ambiental y energético de la edificación mediante el uso de diseño paramétrico, modelado BIM y redes neuronales, logrando reducciones significativas en la energía de climatización, la iluminación artificial y el uso de *clinker* en concordancia con estándares pasivos de alta eficiencia. Por otro lado, la dimensión *Green in* AI aborda la minimización del consumo temporal y energético del sistema informático a través de técnicas de compresión algorítmica, como la poda estructural y la cuantización, evaluando la conservación de la precisión predictiva a pesar de la simplificación del modelo. De este modo, la tabla sintetiza de forma esquemática los objetivos, herramientas, recursos optimizados e impactos cuantitativos de ambos enfoques, evidenciando su complementariedad para lograr un balance ecológico positivo tanto en la infraestructura física como en la esfera digital.

TABLA 4
COMPARATIVA DE ENFOQUES METODOLÓGICOS APLICADOS (DISCUSIÓN)

Característica Comparada	**Dimensión *Green* by AI (IA/BIM para Sostenibilidad Física)**	**Dimensión *Green in* AI (Eficiencia del Proceso Computacional)**
Objetivo Principal	Optimizar el desempeño ambiental y energético de la edificación física (vivienda).	Minimizar el consumo energético y temporal del proceso informático (simulación y entrenamiento).
Metodologías y Herramientas	Diseño paramétrico, BIM (3D/4D/5D), simulación bioclimática y Redes Neuronales Artificiales (ANN) para dosificación.	Compresión algorítmica: Poda estructural (*pruning*) y Cuantización (FP32 a INT8).
Recurso a Optimizar	Recursos Físicos: Energía operacional (kWh/m^2), Clinker/Cemento (t), Residuos y Presupuesto (EVM).	Recursos Digitales: Tiempo de cómputo (horas), Carga de CPU/GPU y Consumo eléctrico informático (kWh).
Impacto Cuantitativo Alcanzado	Reducción del 25.0% en energía de climatización, 40% en iluminación artificial y 20% en uso de clinker.	Reducción del 35.2% en tiempo de procesamiento (142 h a 92 h) y 35.0% en consumo eléctrico digital.
Enfoque de Análisis en la Discusión	Relaciona el ahorro de la vivienda con estándares pasivos de alta eficiencia (ej. *Passivhaus*).	Evalúa la conservación de la precisión predictiva ($R^2 > 88\%$) a pesar de la simplificación del modelo.

La Tabla 4 sintetiza la dualidad metodológica entre la sostenibilidad del entorno construido (*Green by* AI) y la eficiencia del proceso informático (*Green in* AI). Por un lado, la dimensión *Green by* AI articula el diseño paramétrico, BIM (3D/4D/5D) y redes neuronales para optimizar la infraestructura física. Su impacto cuantitativo destaca con reducciones del 25.0% en energía de climatización, 40% en iluminación artificial y 20% en consumo de *clínker*, alineando la edificación con estándares de alta eficiencia como *Passivhaus*. Por otro lado, la dimensión *Green in* AI aborda la huella de carbono digital mediante compresión algorítmica (poda estructural y cuantización de FP32 a INT8). Este enfoque disminuye en un 35.2% el tiempo de procesamiento (de 142 h a 92 h) y en un 35.0% el consumo eléctrico digital, garantizando la viabilidad en zonas con restricciones de cómputo mientras conserva la precisión predictiva ($R^2 > 88\%$). Ambas dimensiones demuestran una complementariedad esencial.

La tabla 5 posiciona los resultados cuantitativos obtenidos en la comunidad de Ayash en relación con estudios previos locales y estándares internacionales citados en la discusión.

TABLA 5
COMPARATIVA DE RESULTADOS OBTENIDOS VS. REFERENCIAS Y ESTÁNDARES

Métrica / Factor Analizado	**Resultado Obtenido Estudio Presente (Ayash, 2026)**	**Análisis y Discusión del Hallazgo**
Reducción Energética Operacional (Climatización)	25.0% (25.7 kWh/m^2/año vs. 42.8 convencional)	Logra un equilibrio superior al abordar simultáneamente el clima severo altoandino y la huella de materiales [3, 7, 16].
Reducción en Demanda de Iluminación Artificial	40.0%	Alineación precisa con los principios de diseño bioclimático pasivo para zonas de alta radiación [3, 7, 12].
Sustitución de *Clinker* en Mezclas Cementicias	20.0% (con incremento del +2.3% en resistencia f'c)	Validado por la literatura [14, 15]; esencial para reducir la logística de transporte de cemento a zonas aisladas [3, 7].
Tiempo de Cómputo e Impacto Digital	92 horas (Ahorro del 35.2% respecto a 142 h)	Demuestra la democratización de la IA al permitir su ejecución en equipos portátiles rurales [3, 7, 18].

La Tabla 5 valida los resultados cuantitativos alcanzados en la comunidad de Ayash (2026) al contrastarlos con la literatura científica y los estándares internacionales. En la dimensión energética, la investigación logra un equilibrio superior frente al clima severo altoandino mediante una reducción del 25.0% en climatización (alcanzando 25.7 kWh/m^2/año frente a 42.8 convencional y un 40.0% en iluminación artificial, alineándose con los principios del diseño bioclimático pasivo. En el ámbito de materiales, la sustitución del 20.0% de *clínker* en mezclas cementicias no solo incrementa la resistencia mecánica en un +2.3% (f′c), sino que optimiza la logística de transporte en zonas aisladas. Finalmente, la reducción del tiempo de cómputo a 92 horas (ahorro del 35.2%) demuestra la democratización de la IA al posibilitar su ejecución en *hardware* portátil en entornos rurales.

IV. CONCLUSIONES

Se demostró la eficacia y solidez técnica del marco integrado del "Algoritmo Verde" (*Green in* AI) y la metodología BIM 3D/5D (*Green by* AI) para el desarrollo de viviendas sostenibles y resilientes en comunidades mineras altoandinas como Ayash (Ancash, Perú). La aplicación de simulaciones bioclimáticas paramétricas en fases tempranas permitió una caracterización precisa de la envolvente arquitectónica, logrando una reducción del 25% en el consumo energético por climatización y una disminución del 40% en la demanda de iluminación artificial. Estos hallazgos validan el uso de la IA para trascender el diseño intuitivo hacia una optimización basada en datos multiobjetivo, en entornos de clima extremo.

La investigación probó que es viable mitigar el impacto ambiental incorporado de la construcción sin sacrificar el desempeño estructural. La optimización de mezclas basada en redes neuronales (ANN) permitió reducir en un 20% el contenido de *clinker*, sustituyéndolo por insumos puzolánicos regionales. Esto no solo generó un concreto con menor huella de carbono, sino que incrementó la resistencia mecánica a la compresión en un +2.3% (21.5 MPa) respecto al control convencional, demostrando que la IA puede gestionar eficazmente la heterogeneidad de los materiales locales para producir compuestos de alto desempeño.

Desde la perspectiva de la sostenibilidad computacional (*Green in* AI), se concluye que la poda algorítmica y la cuantización son estrategias fundamentales para democratizar el uso de tecnologías avanzadas en conos con infraestructura digital limitada. La implementación de estas técnicas en los modelos de IA optimizó el proceso computacional, reduciendo el tiempo de cálculo de 142 a 92 horas (35.2% de ahorro en tiempo y energía eléctrica), manteniendo niveles de precisión predictiva superiores al 88%. Esto prueba que los beneficios ambientales físicos (*Green by* AI) no tienen por qué ser contrarrestados por una huella de carbono digital excesiva.

Asimismo, la integración de la gestión de costos e insumos mediante el marco COST-BIM y el Método del Valor Ganado (EVM) garantizó la estabilidad económica del proyecto. En un entorno volátil como el altoandino, mantener indicadores de desempeño estables (CPI = 1.04, SPI = 1.02) demuestra que la digitalización y la IA son herramientas de predictibilidad financiera esenciales para la viabilidad de proyectos de vivienda social con criterios de sostenibilidad.

A pesar de los resultados positivos, el estudio presenta limitaciones que deben ser abordadas en futuras investigaciones. El enfoque *Green in* AI se centró en la fase de inferencia y simulación; es necesario evaluar el impacto energético del ciclo completo, incluyendo el entrenamiento inicial de los modelos de IA. Además, aunque se validó la resistencia mecánica de los nuevos materiales, se requieren estudios de durabilidad a largo plazo bajo las condiciones cíclicas de congelación y descongelación propias de Ayash.

Finalmente, se recomienda extender la automatización del marco BIM 5D hacia evaluaciones completas del Análisis de Ciclo de Vida (LCA) en tiempo real, vinculando bibliotecas de materiales locales con inventarios de carbono referenciados para el Perú. Para facilitar la escalabilidad del modelo en otras comunidades mineras, se sugiere el desarrollo de plataformas *low-code* que integren estos algoritmos de optimización,

permitiendo a técnicos locales y gobiernos regionales diseñar infraestructura resiliente y de bajo costo operativo sin depender de supercómputo.

AGRADECIMIENTOS

A las Universidades Ricardo Palma (URP) y Santiago Antúnez de Mayolo (UNASAM) por los asesores especialistas y metodólogos que participaron en la elaboración del presente artículo.

REFERENCIAS

[1] Altamirano Ching, J. C., Leandro Flores, I. M., Morales Canal, S. E., & Muñoz Sivana, A. J. (2022). *Casa Ecológica, una opción de viviendas adecuadas sostenibles y de bajo costo* (Tesis de maestría, Pontificia Universidad Católica del Perú). Repositorio Digital PUCP.

[2] Amaya, M., Tovar, D., & Romero, R. (2019). Estudio de viabilidad de la construcción de viviendas sostenibles en una comunidad minera en Perú. Revista Iberoamericana de Ciencias Ambientales, 10(2), 21-34.

[3] Aragón, O., & Cáceres, D. (2015). Hacia la sostenibilidad en la vivienda social: evaluación del desempeño ambiental y energético de viviendas de interés social en la ciudad de Medellín. Revista de Arquitectura, 17(2), 61-72.

[4] Bances, P., & Falla, S. (2015). La tecnología BIM para el mejoramiento de la eficiencia del proyecto multifamiliar "Los Claveles" en Trujillo-Perú (Tesis de pregrado, Universidad Privada Antenor Orrego). Repositorio Digital UPAO.

[5] Briceño, M., Cabanillas, J., Campos, J., & Munayco, H. (2020). Implementación de Gestión BIM para una constructora de Edificios Multifamiliares como soporte del área de planificación de una obra en ejecución (Tesis de maestría, Universidad Peruana de Ciencias Aplicadas). Repositorio Digital UPC.

[6] Cárdenas, C., Zapata, P., & Lozano, N. (2018). Building Information Modeling 5D and *Earned Value Management* methodologies integration through a computational tool. Revista Ingeniería de Construcción, 33(3), 263-278. https://doi.org/10.4067/S0718-50732018000300263.

[7] Chavarry Vallejos, C. M., Támara Rodríguez, J. S., Chavarría Reyes, L. J., Valencia Gutiérrez, A. A., Escobar Serrano, J. C., Chiok Guerra, A. C., & Panana Holgado, E. C. (2026). *Green* Algorithm and Artificial Intelligence for the Sustainability of Civil Infrastructure in Peru. En Proceedings of the 24th LACCEI International Multi-Conference for Engineering, Education, and Technology. Santiago, Chile.

[8] Eyzaguirre Vela, R. (2015). Potenciando la capacidad de análisis y comunicación de los proyectos de construcción, mediante herramientas virtuales BIM 4D durante la etapa de planificación (Tesis de pregrado, Pontificia Universidad Católica del Perú). Repositorio Digital PUCP.

[9] Kumar, B. (2015). A Practical Guide to Adopting BIM in Construction Projects. Whittles Publishing.

[10] Latorre, S., & Aramburú, J. (2018). Vivienda minera sostenible en Perú: una propuesta de modelo habitacional. Revista de Investigación Académica, 21, 1-10.

[11] Leyton Fernández, S. (2020). BIM: Implementación de la metodología para la consultoría de empresas constructoras (Tesis de maestría, Universidad de América). Repositorio Digital Universidad de América.

[12] Passivhaus Institut. (2021). Active for more energy efficiency: Passive House standard. Darmstadt, Alemania.

[13] Savu, C., Pescaru, A.-H., Zsak, I.-G., Durgheu, A.-M., Frent, A.-P., Suba, N.-S., Buda, A. S., & Nistor, S. (2024). Analysis on using 3D scanning and BIM to reduce the physical and non-physical construction waste for sustainable fireproofing of steel trusses. Sustainability, 16(5), Article 1832. https://doi.org/10.3390/su16051832.

[14] Han, T., Siddique, A., Khayat, K., & Huang, J. (2020). Machine learning-based compressive strength prediction and mix design optimization of sustainable concrete. Journal of Cleaner Production, 267, Article 122026. https://doi.org/10.1016/j.jclepro.2020.122026.

[15] Cook, R., Zhang, L., & Mehta, P. (2021). Neural network optimization for low-carbon concrete formulations utilizing industrial by-products. Materials & Design, 198, Aticle 109320. https://doi.org/10.1016/j.matdes.2020.109320.

[16] Zhai, Y., Wang, Y., & Li, X. (2019). Multi-objective optimization of building envelope thermal performance using parametric design and genetic algorithms. Energy and Buildings, 194, 120-133. https://doi.org/10.1016/j.enbuild.2019.04.015.

[17] Lu, Q., Chen, L., & Soo, A. (2021). Machine learning-driven parametric BIM framework for passive solar housing design optimization. Automation in Construction, 126, Article 103670. https://doi.org/10.1016/j.autcon.2021.103670.

[18] Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). *Green* AI: Efficiency in deep learning research and deployment. Communications of the ACM, 63(12), 54-63. https://doi.org/10.1145/3381831.

[19] Wu, X., Zhang, K., & Zhao, Y. (2022). Sustainable computational paradigms in civil engineering: Balancing predictive accuracy and energy footprint. Advanced Engineering Informatics, 52, Article 101580. https://doi.org/10.1016/j.aei.2022.101580.

[20] Soust-Verdaguer, B., Llatas, C., & García-Martínez, A. (2017). Simplification in life cycle assessment of single-family houses: A review of BIM-LCA integration developments. Building and Environment, 103, 215-227. https://doi.org/10.1016/j.buildenv.2016.04.014.

[21] Najjar, M. K., Tam, V. W., Di Maria, A., & Evangelista, A. C. (2022). Integrating BIM-LCA for sustainable housing construction: A quantitative frameworks review. Renewable and Sustainable Energy Reviews, 154, Article 111860. https://doi.org/10.1016/j.rser.2021.111860.

[22] Martínez, E., Castro, R., & Vargas, P. (2021). Social acceptance and technological adaptation of sustainable housing in Andean mining communities. Habitat International, 110, Article 102340. https://doi.org/10.1016/j.habitatint.2021.102340.

[23] Zhao, F., Yu, M., & Tang, L. (2023). Life-cycle cost and carbon footprint assessment of modular eco-housing in high-altitude mineral extraction regions. Journal of Environmental Management, 328, Article 116980. https://doi.org/10.1016/j.jenvman.2022.116980.