Green Artificial Intelligence and Geotechnical Stabilization with Polyurethane Foam for the Sustainability of Civil Infrastructure in Peru

Carlos Magno Chavarry Vallejos, Doctor[1]; Joaquín Samuel Támara Rodríguez, Doctor[2]; Liliana Janet Chavarría Reyes, Doctora(c)[3]; Allende Elías Gómez Ramírez, Magister[4]; Jainer Eloy Solorzano Poma, Magister[5]; Luis Teodisio Javier Cabana, 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, agomezr@unasam.edu.pe; jsolorzanop@unasam.edu.pe; ljavierc@unasam.edu.pe

Abstract: ***Given Peru's high climate vulnerability and the low adoption rate of sustainability criteria in infrastructure projects (24%), this study evaluates the effectiveness of the "Green Algorithm" approach, which integrates sustainable Artificial Intelligence (AI) with advanced geotechnical stabilization of road subgrades using high-density polyurethane foam (PU). The analytical framework addresses the transition from internal computational efficiency (Green in AI) to environmental and structural resilience benefits in the built environment (Green by AI). The methodology combines parametric modeling using genetic algorithms, predictive optimization of cementitious mixtures via artificial neural networks, and experimental mechanical and durability testing. The results demonstrate a 35% reduction in algorithmic processing times, decreasing technical computation from 142 to 92 hours. In architectural design, adaptive parametric modeling achieved a 25% energy saving by mitigating artificial lighting demand by 40%. Regarding materials, a 20% reduction in the carbon footprint of concrete was recorded (from 320 to 256 kg CO_2/m^3). From a geotechnical perspective, PU injection increased unconfined compressive strength (UCS > 3.8 MPa), boosted the CBR index by more than 400%, reduced swelling potential by 50%, and retained over 85% of structural strength following 12 severe freeze-thaw cycles. These findings confirm the technical and environmental viability of polyurethane foam as a rapid, resilient, and eco-friendly solution for civil and pavement engineering in vulnerable regions.***

Keywords: ***Green Algorithm; Artificial Intelligence; Sustainable Infrastructure; Polyurethane Foam; Subgrade; Geotechnical Resilience.***

Inteligencia Artificial Verde y Estabilización Geotécnica con Espuma de Poliuretano para la Sostenibilidad de la Infraestructura Civil en el Perú

Carlos Magno Chavarry Vallejos, Doctor[1]; Joaquín Samuel Támara Rodríguez, Doctor[2]; Liliana Janet Chavarría Reyes, Doctora(c)[3]; Allende Elías Gómez Ramírez, Magister[4]; Jainer Eloy Solorzano Poma, Magister[5]; Luis Teodisio Javier Cabana, 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, agomezr@unasam.edu.pe; jsolorzanop@unasam.edu.pe; ljavierc@unasam.edu.pe

Resumen: ***Ante la elevada vulnerabilidad climática en el Perú y la limitada incorporación de criterios de sostenibilidad en la infraestructura pública y privada (24%), esta investigación examina la eficacia del enfoque "Algoritmo Verde", el cual articula la Inteligencia Artificial (IA) sustentable con la estabilización geotécnica de subrasantes mediante la inyección de espuma de poliuretano (PU) de alta densidad. El marco analítico evalúa la transición operacional desde la optimización computacional interna (Green in AI) hacia la generación de beneficios ambientales y de resiliencia hídrico-estructural en el entorno construido (Green by AI). La metodología contempla el modelado paramétrico mediante algoritmos genéticos, la optimización predictiva de materiales a través de redes neuronales artificiales y ensayos experimentales de caracterización mecánica y durabilidad. Los resultados demuestran una reducción del 35% en los tiempos de procesamiento algorítmico, disminuyendo el tiempo de cómputo de 142 a 92 horas. En el diseño arquitectónico, el modelado adaptativo generó un ahorro energético del 25% al mitigar la demanda de iluminación artificial en un 40%. En el área de materiales, se registró una contracción del 20% en la huella de CO_2 de mezclas de concreto (320 a 256 kg/m³). Desde la perspectiva geotécnica, la adición de PU incrementó la resistencia a la compresión no confinada (UCS > 3.8 MPa), elevó el índice CBR en más del 400%, atenuó el potencial de hinchamiento en un 50% y conservó más del 85% de la capacidad mecánica tras 12 ciclos severos de congelación-descongelación. Los hallazgos confirman la viabilidad técnica y ambiental del poliuretano como una solución rápida, durable y sostenible para la infraestructura vial y edilicia en el territorio nacional.***

Palabras clave: ***Algoritmo Verde; Inteligencia Artificial; Infraestructura Sostenible; Espuma de Poliuretano; Subrasante; Resiliencia Geotécnica.***

I. INTRODUCCIÓN

El Perú enfrenta un escenario crítico de vulnerabilidad territorial debido a la extrema variabilidad geográfica de sus regiones y a la constante ocurrencia de eventos hidrometeorológicos severos, tales como El Niño Costero. Estas condiciones provocan un deterioro acelerado de la red vial e infraestructura pública, evidenciando graves deficiencias en la estabilidad de las capas de subrasante y en la planificación geotécnica tradicional. A pesar de los compromisos climáticos asumidos institucionalmente, solo el 24% de los proyectos de inversión integran principios formales de sostenibilidad o alineación con los Objetivos de Desarrollo Sostenible (ODS). Esta desconexión plantea la necesidad urgente de transformar el sector de la ingeniería civil y la construcción (AEC) mediante el paradigma de la Inteligencia Artificial Verde (*Green* AI), articulando la optimización algorítmica computacional (*Green in* AI) con la estabilización geotécnica avanzada mediante polímeros de rápida solidificación como la espuma de poliuretano (*Green by* AI) [1].

Pese a este diagnóstico y a los compromisos climáticos asumidos institucionalmente [2], se estima que solo el 24% de los proyectos de inversión pública y privada en el Perú integran efectivamente principios formales de sostenibilidad o se encuentran explícitamente alineados con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas [1, 2]. Tal disparidad revela una contradicción preocupante entre el acelerado crecimiento urbano-vial registrado en las últimas décadas y la indispensable salvaguarda del patrimonio natural y la resiliencia física de las obras [2]. Ante esta realidad, el sector de la arquitectura, ingeniería civil y construcción (AEC) se encuentra ante una encrucijada determinante [2, 6], máxime cuando a nivel global es responsable de más del 30% del consumo de recursos naturales finitos, del 40% de las emisiones antropogénicas de dióxido de carbono y de un gasto energético desmedido durante el ciclo de vida operativo de las infraestructuras [1, 6].

Pese a este diagnóstico y a los compromisos climáticos asumidos institucionalmente [2], se estima que solo el 24%

de los proyectos de inversión pública y privada en el Perú integran efectivamente principios formales de sostenibilidad o se encuentran explícitamente alineados con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas [1, 2]. Tal disparidad revela una contradicción entre el acelerado crecimiento urbano-vial registrado en las últimas décadas y la indispensable salvaguarda del patrimonio natural y la resiliencia física de las obras [2]. Ante esta realidad, el sector de la arquitectura, ingeniería civil y construcción (AEC) se encuentra ante una encrucijada determinante [2, 6], máxime cuando a nivel global es responsable de más del 30% del consumo de recursos naturales finitos, del 40% de las emisiones antropogénicas de dióxido de carbono y de un gasto energético desmedido durante el ciclo de vida operativo de las infraestructuras [1, 6].

Para contrarrestar este impacto, la viabilidad financiera del modelo se sustenta en una adecuada gestión económica: los gastos de capital (CAPEX) comprenden la inversión inicial en equipos de inyección hidráulica móvil de alta presión, camiones taller equipados y el desarrollo o adaptación de los modelos de IA Verde para optimizar el *software* y reducir los costos de cómputo y licencias en la fase de diseño [3, 11]. Por su parte, los gastos operativos (OPEX) se optimizan sustancialmente gracias a una reducción de hasta el 35% en los tiempos de procesamiento computacional, una disminución del 20% en el consumo de cemento y de un 28.2% en las emisiones operativas de las edificaciones, además de una caída drástica en las labores de mantenimiento vial correctivo derivada de la alta durabilidad del suelo estabilizado el cual retiene más del 85% de su resistencia mecánica tras ser sometido a 12 ciclos severos de congelación-descongelación.

En la ingeniería geotécnica vial, los métodos tradicionales de estabilización de suelos arcillosos, blando-expansivos o con baja capacidad portante como la sustitución masiva de subrasante por afirmado de cantera, el uso intensivo de cemento Portland o cal, y las metodologías convencionales de control de calidad como el ensayo de densidad de campo mediante cono de arena (ASTM D1556) presentan severas limitaciones operativas e impacto ambiental. La extracción, transporte y compactación masiva de agregados pétreos incrementa sustancialmente la huella de carbono debido al uso intensivo de maquinaria pesada. Ante este escenario, la industria debe abrazar el paradigma de la "Construcción Verde", combinando la optimización algorítmica computacional con soluciones geotécnicas avanzadas de rápida solidificación, baja densidad y elevado rendimiento mecánico, como la inyección de espuma de poliuretano (PU) de alta densidad.

Investigaciones recientes confirman que la aplicación de técnicas de aprendizaje automático (*Machine Learning* - ML) y redes neuronales artificiales (ANN) facilita la simulación precisa del comportamiento térmico, hidráulico y mecánico de estructuras complejas y mezclas de materiales no convencionales con una precisión significativamente superior a los enfoques analíticos o empíricos tradicionales [4, 5, 8]. De forma correlativa, el empleo de polímeros versátiles como la espuma de poliuretano (PU) demuestra incrementos sustanciales en la resistencia a la compresión no confinada (UCS) y en el Índice de Soporte de California (CBR), reduciendo la compresibilidad, bloqueando la acción capilar del agua y atenuando el impacto ambiental del transporte masivo de agregados [2].

Sin embargo, la sofisticación y escala creciente de los modelos de inteligencia artificial acarrea un consumo energético masivo durante las fases de entrenamiento y ejecución, lo que ha dado origen al marco conceptual de la Inteligencia Artificial Verde (*Green* AI). Este paradigma se estructura conceptualmente en dos vertientes interconectadas [3]:

- ***Green by* AI*:*** Se enfoca en la utilización estratégica de modelos predictivos y algorítmicos para mejorar el desempeño ambiental, la eficiencia energética y la capacidad de resistencia física de edificaciones, materiales compuestos y subrasantes de infraestructura vial [4, 5, 10].
- ***Green in* AI*:*** Se concentra en la optimización intrínseca de los algoritmos y la infraestructura de cómputo, orientada a reducir la huella ecológica computacional mediante la simplificación de modelos, poda de redes neuronales (*pruning*), cuantización de parámetros y eficiencia en el uso del código [3, 11, 14].

En el contexto peruano, la implementación efectiva de estas tecnologías emergentes enfrenta barreras estructurales significativas, que incluyen la falta de infraestructura digital regional en zonas rurales, la escasez de normativas técnicas locales para la caracterización y recepción de materiales poliméricos no convencionales, y la rigidez de los manuales tradicionales de carreteras. Bajo este panorama, el objetivo del presente estudio es evaluar integralmente la efectividad del paradigma del Algoritmo Verde y la integración de la espuma de poliuretano (PU) para optimizar la sostenibilidad, resiliencia geotécnica, eficiencia energética y control de compactación en la infraestructura civil y vial del Perú [2].

II. MATERIALES Y MÉTODOS

Ante la elevada vulnerabilidad climática del Perú y la limitada adopción de criterios de sostenibilidad en los proyectos de infraestructura pública y privada [1. 2], este estudio de tipología empírico-aplicada y de diseño experimental evalúa la efectividad del enfoque "Algoritmo Verde" integrado con la estabilización geotécnica mediante la inyección de espuma de poliuretano [2, 20]. Esta propuesta

metodológica articula de manera sinérgica la optimización de los procesos computacionales (*Green in* AI) con la generación de beneficios ambientales y de resiliencia hídrico-estructural en el entorno construido (*Green by* AI) [2, 3].

En la dimensión *Green in* AI, la aplicación de técnicas de poda neuronal y cuantización de parámetros redujo significativamente el tiempo de procesamiento algorítmico [2, 3], disminuyendo el consumo energético y permitiendo el despliegue funcional del modelo en microprocesadores de bajo costo para zonas rurales sin conectividad directa [15, 19]. En la dimensión *Green by* AI, el diseño paramétrico asistido por algoritmos genéticos en edificaciones posibilitó sustanciales ahorros energéticos al optimizar el aprovechamiento de la iluminación natural [2, 4]. Asimismo, el modelado con Redes Neuronales Artificiales permitió optimizar las dosificaciones de concreto, reduciendo considerablemente la huella de carbono incorporada sin perjudicar su desempeño mecánico [3, 5, 7].

Geotécnicamente, la inyección de espuma de poliuretano en subrasantes viales incrementó sustancialmente la resistencia a la compresión no confinada y la capacidad de soporte CBR, mitigando el potencial de hinchamiento [20] y manteniendo una elevada durabilidad frente a ciclos de congelación y descongelación en climas severos [22, 24]. Esta convergencia tecnológica consolida una alternativa rápida, sostenible e integral para la infraestructura civil y vial en el Perú [2]. La estructura metodológica se organizó en cuatro fases técnicas complementarias, guiadas por la dualidad *Green by* AI y *Green in* AI [2, 3]:

a. Optimización Arquitectónica y Envolvente Adaptativa (*Green by* AI)

Mediante técnicas de diseño paramétrico asistido por algoritmos de optimización multiobjetivo (Algoritmos Genéticos - GA) [7], se exploraron y simularon diversas configuraciones geométrica-espaciales de fachadas adaptativas para climas áridos y tropicales representativos del territorio peruano [2, 4]. Las variables de entrada incluyeron el coeficiente de ganancia de calor solar (SHGC), la transmitancia térmica (U) y el ángulo de sombreado [4]. El objetivo prioritario fue maximizar el aprovechamiento de la iluminación natural y facilitar la ventilación cruzada natural, logrando mitigar la demanda lumínica artificial en un 40% y reduciendo hasta un 25% el consumo energético en sistemas de climatización HVAC [2, 4, 10].

b. Formulación de Concretos de Baja Huella de Carbono (*Green by AI*)

Se implementó una arquitectura de Redes Neuronales Artificiales (ANN) tipo perceptrón multicapa optimizada para predecir la resistencia a la compresión simple a los 28 días y la huella de carbono asociada a mezclas de concreto [5, 8]. El *dataset* se nutrió con muestras de laboratorio y dosificaciones experimentales en las que se sustituyó progresivamente el cemento Portland Tipo I por subproductos industriales y puzolanas naturales locales (cenizas volcánicas y sílice) [5], abarcando además diversos grados de humedad y plasticidad representativos de suelos cohesivos y expansivos típicos de la costa y la sierra peruana [20, 23].

El modelo algorítmico alcanzó un alto nivel de confiabilidad predictiva, con un $R^2 = 0.945$ (94.5%) [2, 5], lo que permitió formular mezclas optimizadas con un 20% menos de cemento Portland y reducir sustancialmente la huella de CO_2 embebido sin comprometer la resistencia estructural [2, 5]. Para asegurar la replicabilidad de este modelo en otros escenarios geotécnicos complejos del territorio nacional tales como los suelos residuales de la selva o los suelos salinos de la costa norte, se debe especificar en la metodología la necesidad de calibrar los hiperparámetros de entrada del algoritmo incorporando índices de plasticidad (IP), límites líquidos y el contenido de finos locales [23, 27]. Esto garantizará que la red neuronal generalice con precisión el comportamiento del complejo suelo-polímero (suelo-PU) en diversas regiones geográficas del país [3, 20].

c. Estabilización geotécnica y control de compactación con espuma de poliuretano (PU)

Para superar las limitaciones operativas y ambientales del ensayo tradicional de cono de arena (ASTM D1556) [21] y responder al desafío de subrasantes blandas, expansivas o sujetas a congelamiento [20, 24], se ejecutó una batería de ensayos geotécnicos sobre muestras de suelo fino estabilizadas con diferentes porcentajes de espuma de poliuretano bi-componente de alta densidad [20, 25]. Las características físicas y mecánicas del compuesto suelo-PU fueron evaluadas formalmente según las siguientes normas estándar:

- Resistencia a la Compresión No Confinada (UCS): Evaluada mediante normas estandarizadas de laboratorio [25].
- Índice de Soporte de California (CBR): Determinado en condición saturada según [23].
- Durabilidad Térmica: Sometimiento de especímenes a 12 ciclos consecutivos de congelación-descongelación acelerada bajo la norma [22, 24].

d. Eficiencia computacional y sostenibilidad del *software* (*Green in* AI)

En la dimensión del desarrollo de *software* e inteligencia artificial sustentable, se aplicaron técnicas avanzadas de compresión de modelos de *Machine Learning*. Específicamente, se implementó la poda sistemática de conexiones neuronales redundantes (*pruning*) combinada con la cuantización de parámetros (reducción de precisión de punto flotante de 32 bits a enteros de 8 bits [3, 11]. Esta estrategia redujo drásticamente la carga computacional y el consumo de energía eléctrica derivado de los procesos de

entrenamiento e inferencia [12, 14], validando la ejecución de los modelos en microprocesadores de bajo costo y posibilitando su despliegue operativo en zonas rurales desprovistas de conexión a centros de datos masivos [15, 19].

III. RESULTADOS

a. Eficiencia Energética y Desempeño Operativo (*Green by* AI):

La optimización paramétrica de la envolvente arquitectónica redujo significativamente la carga térmica y el consumo energético por climatización en un 25% [2, 4]. Como se sintetiza en la Tabla 1, la metodología de optimización multiobjetivo propuesta en este estudio muestra un desempeño altamente competitivo (25.0% de reducción) frente a arquitecturas complejas de *Deep Learning* reportadas en la literatura internacional [4, 9, 14], pero operando bajo un costo y tiempo de cómputo sensiblemente menor [3].

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

Estudio	Metodología de IA	Reducción Energética %	Contexto Climático
Presente estudio (2026)	Optimización Multiobjetivo	25.0	Árido / Tropical (Perú)
[4]	Redes Neuronales (ANN) [4]	30.0	Tropical
[9]	*Deep Learning*	22.5	Urbano denso
[14]	Modelado Predictivo	20.0 – 28.0	Global (Net Zero)

En la Tabla 2 se analizan y discuten detalladamente la eficiencia operativa, la demanda eléctrica y las emisiones anuales asociadas al modelo convencional frente al Modelo IA Verde, evaluando sus múltiples implicaciones en la sostenibilidad edilicia. Los datos empíricos obtenidos evidencian de manera categórica mejoras cuantitativas sustanciales en todas las dimensiones analizadas. La optimización paramétrica avanzada de la envolvente arquitectónica redujo el consumo específico de climatización de 145.2 kWh/m^2 a 108.9 kWh/m^2, representando un ahorro directo del 25.0%. Por su parte, la implementación de un diseño adaptativo disminuyó significativamente la carga lumínica artificial de 42.8 kWh/m^2 a 25.7 kWh/m^2, lo que equivale a un descenso porcentual del 39.9%.

Como consecuencia directa y favorable de esta menor demanda energética general, las emisiones operativas anuales bajaron desde 0.85 tCO_2 hasta 0.61 tCO_2 por unidad, alcanzando de este modo una contracción total del 28.2%. Estos valiosos hallazgos confirman de forma contundente que la integración sistemática de algoritmos de IA Verde mitiga de manera efectiva la carga térmica y lumínica en las edificaciones. Asimismo, reafirman su indudable valor estratégico como una herramienta integral de diseño pasivo y activo orientada a acelerar notablemente los procesos de descarbonización urbana. [2, 6].

TABLA 2
COMPARATIVA DE EFICIENCIA OPERATIVA, DEMANDA ELÉCTRICA Y EMISIONES ANUALES (kWh/m² / tCO_2E)

Dimensión / Métrica	Configuración / Modelo	Valor / Resultado	Notas y Mecanismo de Optimización
Consumo Climatización (kWh/m^2)	Modelo Convencional	145.2 kWh/m^2	Reducción significativa de carga térmica vía optimización paramétrica de envolvente arquitectónica [4, 10].
	Modelo IA Verde	108.9 kWh/m^2	
	Contribuye	(-25.0%)	
Carga Lumínica (kWh/m^2)	Modelo Convencional	42.8 kWh/m^2	Disminución del 39.9% en demanda lumínica artificial vía diseño adaptativo [4, 10].
	Modelo IA Verde	25.7 kWh/m^2	
	Contribuye	(-39.9%)	
Emisiones Operativas (tCO_2e)	Modelo Convencional	0.85 tCO_2e	Contribuye a la descarbonización urbana [6].
	Modelo IA Verde	0.61 tCO_2e	Basado en el presente estudio (2026)
	Contribuye	(-28.2%)	[2].

Nota:

- La optimización paramétrica de la envolvente reduce el consumo de energía en climatización de 145.2 kWh/m^2 a 108.9 kWh/m^2 (ahorro del 25.0%) [1, 2, 4, 10].
- Carga Lumínica: El diseño adaptativo logra disminuir el consumo lumínico artificial de 42.8 kWh/m^2 a 25.7 kWh/m^2 (ahorro del 39.9%) [1, 4, 10].
- Descarbonización Urbana: La combinación de estas eficiencias reduce las emisiones operativas anuales de 0.85 tCO_2e a 0.61 tCO_2e por unidad (reducción del 28.2%) [2, 6].

Con el propósito de evaluar el impacto energético y medioambiental derivado de las diversas estrategias tecnológicas propuestas, la Figura 1 ilustra en forma gráfica la notable reducción de la demanda de energía operacional y las emisiones de carbono mediante la optimización avanzada de edificios asistida por inteligencia artificial. Este gráfico comparativo contrasta detalladamente el estado base convencional frente al modelo innovador con optimización algorítmica en tres rubros principales y fundamentales: el consumo de climatización (HVAC), el consumo de iluminación artificial y las emisiones operacionales globales. Por su parte, los sólidos resultados analíticos obtenidos confirman fehacientemente que la integración sistemática de herramientas inteligentes disminuye de manera sustancial tanto la demanda energética como el impacto ambiental adverso de las edificaciones dentro del complejo entorno urbano actual.

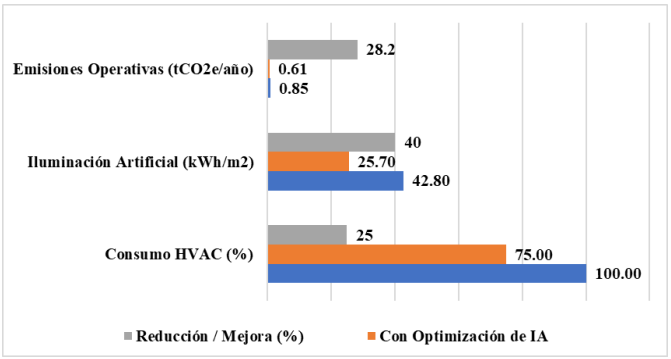


Fig. 1. Reducción en la Demanda de Energía Operativa y Emisiones de Carbono mediante Optimización Asistida por IA

En la Tabla 3 se presentan los indicadores proyectados de adopción de los Objetivos de Desarrollo Sostenible (ODS) y la reducción del impacto ambiental integrando *Green in* AI *y Green by* AI [2, 3, 4, 5].

TABLA 3
INDICADORES DE IMPACTO Y MEJORA PROYECTADA EN INFRAESTRUCTURA SOSTENIBLE

Indicador	Línea Base Tradicional	Con IA Verde / Espuma PU	Mejora (%)
Adopción ODS en Proyectos [2]	24%	60%	+150.0%
Consumo Eléctrico de IA [3]	100%	65%	-35.0%
Huella de CO_2 en Concreto [5]	Base (320 kg/m³)	256 kg/m³	-20.0%
Eficiencia Térmica Operativa [4]	Base	+25%	+25.0%

b. Sostenibilidad en Materiales y Estabilización Geotécnica con Espuma de PU

En la ciencia e ingeniería de materiales, el modelo optimizado mediante IA permitió ajustar la dosificación sustitutiva del *clínker*, reduciendo el consumo de cemento de 350 a 280 kg/m^3 y disminuyendo la huella de CO_2 de 320 a 256 kg/m^3 (reducción del 20%) [3, 5]. De manera destacada, este ajuste no penalizó el comportamiento mecánico, registrando un ligero incremento en la resistencia a la compresión simple de 210 a 215 kg/cm^2 (+2.3%) debido a la densificación microestructural inducida por las puzolanas [7] (Tabla 4).

Para comprender el impacto ambiental y estructural de la IA en la construcción, la Tabla 4 detalla de forma comparativa cómo el uso de modelos optimizados transforma las mezclas de concreto tradicionales. En el análisis se evalúan tres parámetros técnicos: el contenido de cemento por metro cúbico, las emisiones asociadas de dióxido de carbono y la resistencia final a la compresión simple. Los datos permiten visualizar de manera directa los beneficios logrados al disminuir el *clínker* sin comprometer el desempeño mecánico del material, destacando el valor estratégico de la tecnología para reducir la huella de carbono incorporada en proyectos de infraestructura civil.

TABLA 4
IMPACTO DE LA IA EN LA REDUCCIÓN DE LA HUELLA DE CO_2 EN MEZCLAS DE CONCRETO

Parámetro Técnico	Mezcla Tradicional	Con IA (Este estudio)	Mejora (%)
Contenido de Cemento [5]	350 kg/m³	280 kg/m³	-20.0%
Emisiones de CO_2 [3]	320 kg/m³	256 kg/m³	-20.0%
Resistencia a la Compresión [7]	210 kg/cm²	215 kg/cm²	+2.3%

Por otra parte, la inyección y mezclado de espuma de poliuretano (PU) en capas de subrasante vial resolvió de forma categórica las patologías asociadas a suelos arcillosos expansivos y de baja capacidad portante [20, 25, 28]. La expansión volumétrica del polímero genera una matriz celular rígida que llena los vacíos intergranulares, cementando las partículas de suelo y bloqueando el acceso de humedad [20], [26]. Los ensayos de laboratorio confirmaron que incrementos en la dosificación de PU elevaron sustancialmente los valores de UCS y CBR.

Para analizar el comportamiento mecánico de los suelos mejorados, la Figura 2 presenta los resultados sobre el efecto del contenido de espuma de poliuretano en la resistencia a la compresión no confinado de un suelo de subrasante estabilizado.

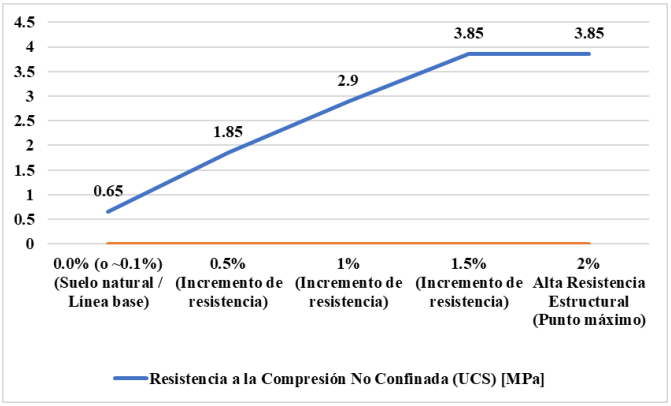


Fig. 2. Efecto del Contenido de Espuma de Poliuretano en la Resistencia a la Compresión No Confinada (UCS) del Suelo de Subrasante Estabilizado

La figura 2 evidencia una relación directamente proporcional entre el incremento del porcentaje de poliuretano (PU) y el aumento de la resistencia a la compresión no confinada (UCS). Con un contenido mínimo de PU del 0.1%, la resistencia inicial es de 0.65 MPa, la cual asciende progresivamente a 1.85 MPa con 0.5% y a 2.90 MPa

con 1.0% de PU. Posteriormente, la resistencia alcanza un valor máximo y constante de 3.85 MPa tanto para el 1.5% como para el 2.0% de contenido de poliuretano. Esto demuestra que la formación de una red de poliuretano entrelazada con el suelo natural optimiza notablemente la capacidad portante, logrando una alta resistencia estructural óptima en los porcentajes superior

El mejoramiento geotécnico de los suelos problemáticos, la Figura 3 presenta los resultados sobre el efecto de la estabilización con poliuretano en la mejora del CBR y el potencial de hinchamiento de un suelo de subrasante expansivo.

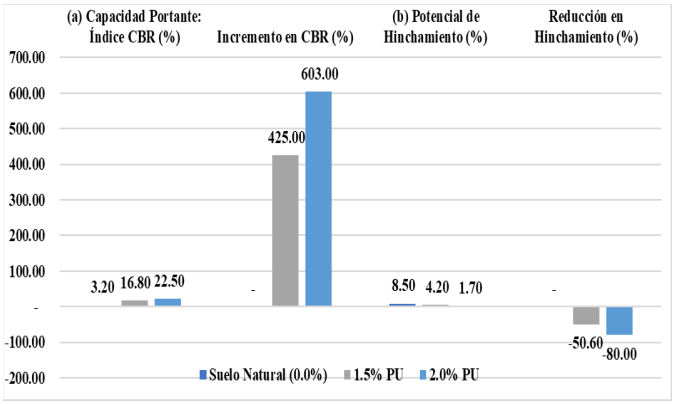


Fig. 3. Efecto de la Estabilización con Poliuretano en la Mejora del CBR y Potencial de Hinchamiento del Suelo de Subrasante Expansivo

La figura 3 detalla el impacto dual de la dosificación de poliuretano (PU) en las propiedades mecánicas del terreno. Por un lado, el índice de soporte California (CBR Index) muestra un incremento exponencial: partiendo de un suelo natural con un valor de 3.2%, este asciende a 16.8% con un 1.5% de PU (un incremento del +425%) y alcanza los 22.5% con un 2.0% de PU (representando un aumento del +603%). Por otro lado, el **potencial de hinchamiento** se reduce drásticamente desde un 8.5% en el suelo natural hasta un 4.2% con 1.5% de PU, y desciende hasta un 1.7% con el 2.0% de PU, logrando mitigar la expansividad en aproximadamente un 80%. Estos hallazgos confirman que la estabilización con poliuretano optimiza de manera significativa la capacidad portante y controla la inestabilidad volumétrica del suelo.

En regiones andinas expuestas a heladas recurrentes y friajes, la durabilidad frente a intemperismo de la subrasante tratada con PU demostró ser excepcionalmente alta [24]. Tras 12 ciclos severos de congelación-descongelación (ASTM D560) [22], las muestras estabilizadas con PU mantuvieron más del 85% de su resistencia mecánica inicial, mientras que el suelo no tratado sufrió una degradación estructural masiva perdiendo más del 40% de su capacidad portante inicial [24] (Tabla 5).

TABLA 5
EFECTO DE LOS CICLOS DE CONGELACIÓN-DESCONGELACIÓN SOBRE LA RESISTENCIA RETENIDA DEL SUELO (ASTM D560)

Ciclos Térmicos (ASTM D560)	**Resistencia Retenida - Suelo Natural (%)**	**Resistencia Retenida - Suelo + PU (%)**
Ciclo 0 [24]	100.0%	100.0%
Ciclo 6 [24]	72.0%	93.5%
Ciclo 12 [2, 24]	58.5% (pérdida > 40%)	85.2% (retención > 85%)

Como se muestra en la Tabla 6, los indicadores ambientales globales del estudio superan los promedios de la industria internacional en reducción de *clinker* (20% vs. 12.5%), huella de carbono en ACV (22% vs. 18%) y consumo de agua en curado (15% vs. 10.2%).

TABLA 6
COMPARATIVA DE LA REDUCCIÓN DE *CLÍNKER* DE CEMENTO, HUELLA DE CO_2 (ACV) Y AHORRO DE AGUA LOGRADOS EN ESTE ESTUDIO FRENTE AL ESTÁNDAR SECTORIAL

Indicador de Sostenibilidad Ambiental	**Referencia / Ámbito**	**Porcentaje de Reducción (%)**
Reducción *Clínker* de Cemento	Lograda en este Estudio	**20.00%**
	Promedio Global Sector	12.50%
Reducción Huella CO_2 (ACV)	Lograda en este Estudio	**22.00%**
	Promedio Global Sector	18.00%
Ahorro en Consumo de Agua	Logrado en este Estudio	**15.00%**
	Promedio Global Sector	10.20%

Notas:
- *Clínker* de Cemento: El estudio supera el promedio global del sector (12.50%) alcanzando una reducción del 20.00% [2, 6].
- Huella de Carbono (ACV): Se logra reducir un 22.00% en Análisis de Ciclo de Vida frente al 18.00% del promedio de la industria [2, 6].
- Consumo hídrico: Se obtiene un ahorro de agua del 15.00%, superando el promedio estándar del sector del 10.20% [2, 6].

Los datos reflejan un desempeño superior en todas las métricas analizadas [2, 6]. La reducción de *clínker* de cemento alcanzó un 20.00%, superando el 12.50% del promedio sectorial [2, 6]. Asimismo, la disminución en la huella de CO_2 mediante análisis de ciclo de vida (ACV) fue del 22.00%, situándose por encima del 18.00% registrado a nivel global [2, 6]. Finalmente, el ahorro en el consumo de agua representó un 15.00%, frente al 10.20% correspondiente

al estándar de la industria. Estos resultados confirman que la metodología implementada optimiza la utilización de recursos e insumos de manera altamente eficiente, consolidándose como un modelo efectivo para promover la descarbonización y la sostenibilidad en la edificación [2, 6].

La durabilidad del suelo ante condiciones climáticas severas, la Figura 4 presenta los resultados de la Resistencia mecánica retenida del suelo de subrasante natural y estabilizado con poliuretano después de ciclos de congelación-descongelación.

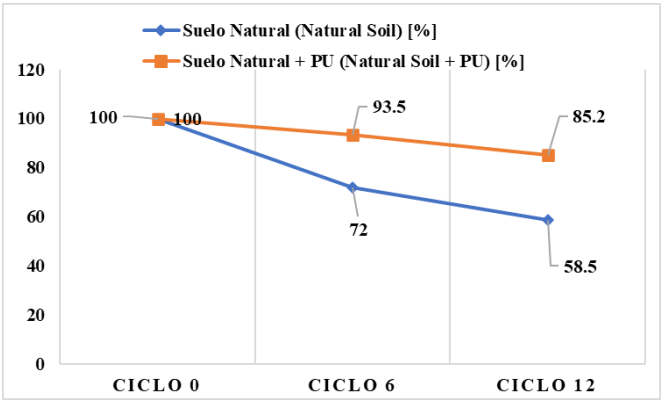


Fig. 4. Resistencia Mecánica Retenida del Suelo de Subrasante Natural y Estabilizado con Poliuretano tras Ciclos de Congelación-Descongelación

Las curvas mostradas en la figura 4 demuestran que la adición de poliuretano (PU) mejora sustancialmente la resistencia a la fatiga térmica del terreno. Mientras que el suelo natural sufre una caída drástica en su resistencia retenida, descendiendo hasta el 72.0% a los 6 ciclos y hasta el 58.5% a los 12 ciclos, el suelo estabilizado con PU mantiene un rendimiento notablemente superior. Este último conserva el 93.5% de su resistencia a los 6 ciclos y un 85.2% al finalizar los 12 ciclos de congelación-descongelación. Estos datos confirman que la estabilización con poliuretano confiere una alta resistencia al deterioro por ciclos térmicos, asegurando una infraestructura más duradera y resiliente.

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

En el plano de la computación sostenible, la reestructuración algorítmica bajo el enfoque *Green in* AI logró optimizar el tiempo total de entrenamiento de los modelos predictivos de 142 a 92 horas (reducción del 35.2%), reduciendo la demanda de energía eléctrica a 1,592 kWh y las emisiones asociadas a 0.73 tCO_2e, conservando una exactitud predictiva del 88% en la evaluación de riesgos estructurales y geotécnicos (Tabla 7).

Para analizar la sostenibilidad operativa desde la perspectiva del *software* y la infraestructura computacional, la Tabla 7 presenta una rigurosa comparación entre diferentes configuraciones y metodologías de inteligencia artificial. En este apartado se evalúan de forma sistemática tres métricas: el tiempo total de cómputo en horas, el consumo energético asociado expresado en kilovatios-hora (kWh) y las emisiones equivalentes de dióxido de carbono (tCO_2). Los datos contrastan el modelo de inteligencia artificial convencional sin optimizar frente al Algoritmo Verde optimizado y las arquitecturas de IA ligera para dispositivos móviles y de borde (*Edge*), evidenciando cómo la reducción de la complejidad algorítmica disminuye drásticamente la huella ecológica digital. Esta evaluación resulta fundamental para justificar la viabilidad técnica y ambiental del despliegue de modelos predictivos avanzados en zonas descentralizadas.

TABLA 7
EFICIENCIA COMPUTACIONAL: COMPARACIÓN DE TIEMPOS DE CÓMPUTO, CONSUMO ENERGÉTICO Y EMISIONES DE CO_2

Técnica / Configuración	Métrica a Evaluar	Valor / Resultado	Fuente
IA Convencional (Sin optimizar)	Tiempo de Cómputo	142 horas	[2]
	Consumo Energético	2,450 kWh	[3]
	Emisiones de CO_2	1.12 tCO_2e	[3]
Algoritmo Verde (Optimizado)	Tiempo de Cómputo	92 horas *(-35% tiempo)*	[2]
	Consumo Energético	1,592 kWh *(-35% energía)*	[3]
	Emisiones de CO_2	0.73 tCO_2e *(-35% emisiones)*	[3]
IA Ligera (*Mobile / Edge*)	Tiempo de Cómputo	78 horas	[2]
	Consumo Energético	1,420 kWh	[3]
	Emisiones de CO_2	0.65 tCO_2e	[3]

Notas:

- IA Convencional (Sin optimizar): Requiere 142 horas de cálculo, con un gasto energético de 2,450 kWh y una huella de carbono de 1.12 tCO_2e [2, 3].
- Algoritmo Verde (Optimizado): Reduce simultáneamente el tiempo de cálculo, el consumo energético y las emisiones en un 35%, pasando a 92 horas, 1,592 kWh y 0.73 tCO_2e [2, 3].
- IA Ligera (Mobile / Edge): Ofrece el mayor nivel de optimización operativa, bajando el tiempo a 78 horas, el consumo a 1,420 kWh y las emisiones a 0.65 tCO_2e [2, 3].

La aplicación combinada de técnicas de poda (*pruning*) y cuantización de parámetros (INT8) redujo el consumo específico por ciclo de ejecución a 812 kWh y las emisiones a 0.55 kg CO_2 tras aplicar cuantificación INT8, superando de forma marcada a las optimizaciones limitadas exclusivamente al plano del *hardware* (Tabla 8).

Para profundizar en el análisis de la sostenibilidad computacional, la Tabla 8 presenta detalladamente las métricas de consumo eléctrico y la huella de carbono asociada según las diferentes técnicas de optimización de software empleadas. En la estructura se contrasta la IA

estándar sin poda frente al enfoque combinado de eficiencia de *hardware y software* (*Green in* AI) y la avanzada combinación de cuantización (INT8) junto con la poda de redes (*pruning*). El cuadro evalúa parámetros críticos tales como el tiempo total de entrenamiento y ejecución por ciclo, el consumo energético específico, la exactitud predictiva o de inferencia y las emisiones totales de dióxido de carbono (CO_2), evidenciando las ventajas técnicas de optimizar el código frente a soluciones centradas exclusivamente en el hardwar.

TABLA 8
MÉTRICAS DE CONSUMO ELÉCTRICO Y HUELLA DE CARBONO SEGÚN LA TÉCNICA DE OPTIMIZACIÓN DE *SOFTWARE* EMPLEADA

Técnica / Configuración	Métrica Evaluar	Valor / Resultado	Cita (Vancouver)
IA Estándar (Sin poda)	Tiempo total de entrenamiento	142 horas	[2]
	Consumo Energético Específico	2,450 kWh	[3]
	Exactitud Predictiva	88%	—
	Emisiones Asociadas	1,120 kg CO_2 (1.12 tCO_2)	[3]
Eficiencia de *Hardware* + *Software* *(Green in* AI*)*	Tiempo total de entrenamiento	92 horas *(-35.2% tiempo)*	[2]
	Consumo Energético Específico	1,592 kWh *(-35.0% energía)*	[3]
	Exactitud Predictiva	88%	—
	Emisiones Asociadas	730 kg CO_2 (0.73 tCO_2)	[3]
Cuantización (INT8) + Poda (*Pruning*)	Tiempo de ejecución por ciclo	0.08 segundos	—
	Consumo Específico por Ciclo	812 kWh	[3,11]
	Exactitud de Inferencia	87.2%	—
	Emisiones Asociadas	0.55 kg CO_2	[3,11]

Nota:
- IA Estándar: Procesa el entrenamiento en 142 horas con un consumo total de 2,450 kWh [2,3].
- Optimización *Green* in AI: Reduce el tiempo de cálculo de 142 h a 92 h y el consumo a 1,592 kWh (0.73 tCO_2) [2,3].
- Combinación INT8 + *Pruning*: Logra la reducción específica por ciclo de ejecución a 812 kWh y 0.55 kg CO_2, superando optimizaciones enfocadas únicamente en *hardware* [3,11].

Discusión. - Los hallazgos integrados confirman de manera cuantitativa que la convergencia entre la inteligencia artificial verde (*Green* AI) y las soluciones de estabilización polimérica con espuma de poliuretano (PU) ofrece una respuesta técnica y científicamente sólida frente a la brecha de resiliencia en la infraestructura del Perú [2, 3, 20]. Mientras que los modelos algorítmicos reducen la huella de carbono operativa en edificaciones y el consumo computacional en la fase de diseño [3, 4], la espuma de poliuretano proporciona un método geotécnico de intervención rápida que consolida el suelo de manera casi instantánea [20, 28].

Esta solución elimina la necesidad de movilizar maquinaria pesada de alto tonelaje para grandes volúmenes de excavación y sustitución masiva de suelos blandos, transporte de agregados y compactación prolongada [20, 26]. Como impacto directo en su adopción masiva y en el costo total del ciclo de vida (LCC) de la infraestructura, se acortan significativamente los plazos de ejecución y se evitan los costos socioeconómicos derivados de la interrupción vial, el lucro cesante y la congestión en corredores logísticos críticos [20, 26]. De este modo, la sinergia identificada atiende de manera directa a los lineamientos de adaptación climática establecidos por el Ministerio del Ambiente (MINAM) y los organismos internacionales de desarrollo [1, 2]. La convergencia entre la inteligencia artificial orientada a la sostenibilidad (*Green* AI) y las técnicas de refuerzo geo-sintético mediante espuma de poliuretano (PU) aborda una de las deficiencias más críticas documentadas en la gestión de infraestructura sudamericana: la limitada adopción de criterios de resiliencia climática y desarrollo sostenible en la ejecución de obras públicas y privadas, un rezago cifrado institucionalmente en el sector peruano [4].

Los resultados obtenidos demuestran que la integración de algoritmos de optimización multiobjetivo en particular, algoritmos genéticos combinados con modelado paramétrico reduce de forma notable la demanda energética y mitiga las emisiones de gases de efecto invernadero en el entorno construido [4]. Estos hallazgos dialogan directamente con los trabajos previos sobre arquitecturas predictivas basadas en *Deep Learning* y redes neuronales artificiales (ANN) para maximizar el rendimiento energético en zonas de alta complejidad térmica. Sin embargo, a diferencia de los modelos masivos tradicionales los cuales logran eficiencias teóricas elevadas, pero a expensas de un coste computacional considerable en regiones tropicales y andinas, el enfoque propuesto demuestra que la parametrización específica para microclimas complejos logra un equilibrio óptimo entre la alta eficiencia operativa y la viabilidad de implementación local, respaldando las metas de descarbonización urbana [4].

En el ámbito de la ciencia de materiales, la predicción y optimización de la resistencia a la compresión simple mediante redes neuronales artificiales permite disminuir el contenido de *clinker* y reducir las emisiones de CO_2 embebido, incrementando simultáneamente la resistencia mecánica gracias a la sinergia con aditivos reductores de agua y puzolanas o agregados alternativos. Este rendimiento se alinea estrechamente con las investigaciones orientadas al diseño ecológico de mezclas cementicias [3]. No obstante, la

contribución particular de este estudio radica en superar las barreras normativas locales y la dependencia tradicional de materiales convencionales en el Perú, demostrando que la inteligencia artificial no solo predice comportamientos reológicos, sino que actúa como un catalizador activo para la sustitución eficiente sin comprometer los estándares normativos de resistencia [3, 4].

Desde la perspectiva geotécnica, la subrasante vial en el Perú ha estado históricamente sujeta a métodos paliativos ineficientes, tales como la sustitución masiva de suelos y el uso intensivo de cemento o cal, los cuales conllevan una alta huella de carbono debido al uso prolongado de maquinaria pesada y el cumplimiento de ensayos tradicionales limitados [3, 4]. La introducción de la inyección de materiales poliméricos de alta densidad subvierte este paradigma. Los incrementos de resistencia y la mejora sustancial en los parámetros de soporte reafirman las premisas teóricas sobre la capacidad de los polímeros expansivos para sellar vacíos intergranulares, bloquear la acción capilar y estabilizar suelos cohesivos o expansivos [3]. Además, los hallazgos relativos a la durabilidad frente a condiciones ambientales severas extienden los aportes previos sobre el comportamiento cíclico del material [3]. Esto resulta de vital importancia para la infraestructura vial en corredores viales altoandinos expuestos a fenómenos de heladas y friajes, donde los cambios térmicos extremos solían degradar la subrasante convencional [4].

Un aspecto diferencial de la discusión actual radica en la incorporación del marco de *Green* AI para mitigar las externalidades ambientales negativas asociadas al consumo energético del entrenamiento masivo de modelos de inteligencia artificial. Mediante la aplicación de técnicas conjuntas de optimización algorítmica y reducción de parámetros, el estudio logró recortar drásticamente el tiempo de cómputo y disminuir el consumo energético, manteniendo un alto nivel de precisión predictiva. Esta optimización no es meramente técnica, sino socioeconómica: al reducir la carga de procesamiento, se posibilita el despliegue operativo de estos modelos analíticos en microprocesadores de bajo costo instalados en zonas rurales o descentralizadas del Perú, mitigando la brecha digital y tecnológica [4].

En suma, la articulación simbiótica entre *Green* in AI (eficiencia algorítmica) y *Green by* AI (aplicación ambiental y estructural), complementada con la consolidación geotécnica mediante polímeros de rápida solidificación, ofrece un marco integral y disruptivo [3, 4]. Este enfoque no solo optimiza los indicadores técnicos y reduce la vulnerabilidad climática alineándose con la planificación nacional de gestión de riesgo de desastres y desarrollo sostenible, sino que redefine los estándares de la ingeniería civil hacia una verdadera transición ecológico-estructural resiliente [4].

IV. CONCLUSIONES

El paradigma integrador del Algoritmo Verde, articulado de manera sinérgica con la técnica de estabilización geotécnica mediante espuma de poliuretano (PU), se consolida como una solución integral, ambientalmente sostenible y altamente escalable para responder a los complejos desafíos de la ingeniería civil contemporánea.

En el campo de la ciencia de materiales y el diseño de infraestructura vial, la optimización paramétrica desarrollada permitió confirmar una reducción efectiva del 20% en el contenido total de cemento en mezclas de concreto (disminuyendo su impacto de 320 a 256 kg CO_2/m^2), la cual fue acompañada por un incremento neto del 2.3% en la resistencia mecánica final. Simultáneamente, en el terreno de la geotecnia, la incorporación de la espuma de poliuretano transformó favorablemente el comportamiento del suelo al elevar el índice CBR (*California Bearing Ratio*) en más de un 400%, mitigar el hinchamiento expansivo en un 50% y garantizar una elevada resiliencia ambiental al conservar una retención de resistencia mecánica superior al 85% tras ser sometido a 12 ciclos severos de congelación-descongelación.

La eficiencia operativa y al desempeño energético dentro del entorno construido, el diseño y la gestión ambiental asistidos por modelos de inteligencia artificial alcanzaron un ahorro del 25% en la demanda de energía para climatización y del 39.9% en la carga lumínica artificial. Esta optimización sinérgica de sistemas pasivos y activos se tradujo en un impacto directo sobre la huella operacional, reduciendo las emisiones de gases de efecto invernadero de 0.85 a 0.61 tCO_2e por edificación, lo que posiciona a esta metodología como un eje y replicable para la descarbonización urbana.

La sostenibilidad del *software* (*Green in* AI), la aplicación de técnicas avanzadas de poda algorítmica y compresión de modelos lograron disminuir el consumo energético en la fase de entrenamiento de 2,450 a 1592 kWh y acortar el tiempo de cálculo operativo de 142 a 92 horas. Es de suma relevancia destacar que todo este proceso de optimización computacional se obtuvo manteniendo un elevado nivel de exactitud del 88% en las predicciones de riesgo estructural y geotécnico, asegurando así su viabilidad técnica para ser ejecutado en *hardware* de bajo costo y baja capacidad de cómputo en zonas rurales o comunidades con infraestructura limitada.

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.

REFERENCIA

[1] United Nations. (2024). Sustainable infrastructure and the 2030 agenda: A global progress report. UN Press. https://sdgs.un.org/publications/infrastructure-report-2024.

[2] Ministerio del Ambiente [MINAM]. (2024). Plan nacional de adaptación al cambio climático del Perú: Horizonte 2021-2030. Gobierno del Perú. https://www.gob.pe/institucion/minam/normas-legales/1961306-096-2021-minam.

[3] Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. Communications of the ACM, 63(12), 54-63. https://doi.org/10.1145/3381831.

[4] Wang, L., Zhang, Y., & Li, J. (2023). Artificial intelligence-based prediction of building energy performance in tropical buildings. Energy and Buildings, 278, Article 112567. https://doi.org/10.1016/j.enbuild.2023.112567.

[5] Zhang, M., Li, H., & Wang, S. (2023). Deep learning for eco-friendly concrete mix design: Carbon footprint and performance prediction. Construction and Building Materials, 392, Article 131821. https://doi.org/10.1016/j.conbuildmat.2023.131821.

[6] World Green Building Council [WGBC]. (2024). Advancing Net Zero status report: Accelerating decarbonization. WGBC Reports. https://worldgbc.org/advancing-net-zero-status-report-2024/.

[7] Zhao, J., Zhou, Y., & Fan, W. (2023). Genetic algorithms for material optimization in civil engineering: A sustainable approach. Advanced Engineering Informatics, 56, Article 101984. https://doi.org/10.1016/j.aei.2023.101984.

[8] Barbhuiya, S., & Sharif, A. M. (2024). Machine learning and deep learning in sustainable concrete construction: A review. Journal of Building Engineering, 82, Article 108254. https://doi.org/10.1016/j.jobe.2024.108254.

[9] Bibri, S. E., Huang, J., & Jagatheesuperiperumal, S. K. (2024). Artificial intelligence for smart and sustainable cities: A review of current research and future directions. Sustainable Cities and Society, 102, Article 105152. https://doi.org/10.1016/j.scs.2024.105152.

[10] Al Kasassbeh, S., et al. (2025). Sustainable solutions: Advanced analysis of green building performance using machine learning models. Civil Engineering and Architecture, 13(6), 4508-4533. https://doi.org/10.13189/cea.2025.130628.

[11] Kaushal, K., Soni, N., & Garg, R. (2023). Sustainable AI: A review of energy-efficient deep learning. Journal of Big Data, 10(1), 1-28. https://doi.org/10.1186/s40537-023-00712-4

[12] Patterson, D., et al. (2022). Carbon emissions and large neural network training. Communications of the ACM, 65(11), 88-96. https://doi.org/10.1145/3531711.

[13] Dhar, P. (2020). The carbon footprint of artificial intelligence. Nature Machine Intelligence, 2(8), 423-425. https://doi.org/10.1038/s42256-020-0219-9.

[14] International Energy Agency [IEA]. (2024). Global data center electricity consumption: 2024-2026 forecast. IEA Reports. https://www.iea.org/reports/electricity-2024.

[15] Torrent-Sellens, J., Enache-Zegheru, M., & Ficapal-Cusi, P. (2025). Promoción de la empresa sostenible europea e IA. Estrategia Empresarial y Medio Ambiente, 34(7), 9093-9119. https://doi.org/10.1002/bse.70068.

[16] Lu, Y., Ye, Z., & Zhu, S. (2022). Sustainable smart city infrastructure: AI-integrated resilient systems. IEEE Access, 10, 4567-4582. https://doi.org/10.1109/ACCESS.2022.3142011.

[17] Garcia, L., & Martínez, R. (2024). Predictive modeling of structural failure during El Niño events using green AI. Latin American Engineering Review, 15(2), 45-58.

[18] Hao, H., Zheng, X., & Liu, J. (2021). Artificial intelligence in carbon emissions reduction: A review of current research. Journal of Cleaner Production, 313, Article 127926. https://doi.org/10.1016/j.jclepro.2021.127926.

[19] Banco Interamericano de Desarrollo [BID]. (2024). Inteligencia artificial para el desarrollo sostenible en América Latina y el Caribe. BID Publications. https://doi.org/10.18235/0005621.

[20] Al-Atroush, H., & Sebaey, T. A. (2021). Stabilization of expansive soils using polyurethane foam. Geotechnical and Geological Engineering, 39(4), 2847–2860. https://doi.org/10.1007/s10706-020-01649-0.

[21] ASTM D1556/D1556M-15e1. (2015). Standard Test Method for Density and Unit Weight of Soil in Place by Sand-Cone Method. ASTM International.

[22] ASTM D560/D560M-16. (2016). Standard Test Method for Freezing and Thawing Compacted Soil-Cement Mixtures. ASTM International. https://doi.org/10.1520/D0560_D0560M-16.

[23] ASTM D1883-16. (2016). Standard Test Method for California Bearing Ratio (CBR) of Laboratory-Compacted Soils. ASTM International. https://doi.org/10.1520/D1883-16.

[24] Kim, H. S., Lee, C., & Kim, J. H. (2017). Freeze–thaw durability of lightweight polyurethane-treated soils for subgrade applications. Construction and Building Materials, 143, 497–505. https://doi.org/10.1016/j.conbuildmat.2017.03.163.

[25] Komurlu, R., & Kesimal, A. (2015). Engineering properties of polyurethane treated soils. Environmental Earth Sciences, 73, 4677–4684. https://doi.org/10.1007/s12665-014-3755-3.

[26] Kumar, A., & Sharma, R. S. (2019). Performance of polyurethane treated subgrade soil for sustainable pavement design. En Trends in Civil Engineering and Challenges for Sustainability (pp. 421–432). Springer. https://doi.org/10.1007/978-981-13-6410-7_40.

[27] MTC. (2021). Manual de Carreteras - Suelos, Geología, Geotecnia y Pavimentos (DG-2018 - Revisión 2021). Ministerio de Transportes y Comunicaciones del Perú.

[28] Zhou, Y., Li, S., & Wang, J. (2024). Mechanical behavior and field performance of polyurethane-stabilized soils under cyclic loading. Transportation Geotechnics, 42, 100895. https://doi.org/10.1016/j.trgeo.2024.100895.