

Optimización Multicriterio de Cubiertas en Almacenes Aeroportuarios mediante Diseño Generativo y Simulación Climática: Caso de Estudio en Arquitectura Industrial Aeroportuaria

Multi-Criteria Optimization of Roof Systems in Airport Warehouses through Generative Design and Climate Simulation: A Case Study in Airport Industrial Architecture

Jhordan Renzzo Cabel Aguilera * 

Colegio de Arquitectos del Perú Regional Lima, Av. San Felipe 999, Jesús María, Lima, Perú.

* Autor correspondiente: jhordan.cabel@gmail.com (J. Cabel)

DOI: [10.17268/scien.inge.2026.03.02](https://doi.org/10.17268/scien.inge.2026.03.02)

RESUMEN

Esta investigación explora el uso del diseño generativo y la simulación climática temprana para optimizar cubiertas industriales en almacenes semiabiertos del Aeropuerto Internacional Jorge Chávez. Se comparan tres soluciones: la original del cliente, una propuesta arquitectónica entregada en el ejercicio profesional y una alternativa generada mediante algoritmos de optimización multiobjetivo asistidos por aprendizaje automático. Usando herramientas como Ladybug Tools y Wallacei X, se evaluó el desempeño ambiental a partir de datos EPW, con énfasis en cobertura de sombra, UTCI y MRT. Los resultados revelan que, aunque la solución entregada al cliente cumple con los parámetros medidos, la solución generativa mejora el rendimiento técnico de la propuesta original con una geometría más optimizada bajo múltiples criterios de optimización. El estudio confirma el potencial del diseño computacional en fases iniciales de proyectos industriales, optimizando el desempeño pasivo bajo restricciones técnicas y operativas reales.

Palabras clave: Diseño Generativo; Simulación Climática; Arquitectura Paramétrica; Cubiertas Industriales; Optimización Multiobjetivo.

ABSTRACT

This research explores the application of generative design and early-stage climate simulation to optimize industrial roof systems in semi-open warehouses at Jorge Chávez International Airport. Three design solutions are compared: the client's original scheme, an architectural proposal developed during professional practice, and an alternative generated through multi-objective optimization algorithms supported by machine learning. Using tools such as Ladybug Tools and Wallacei X, environmental performance was assessed based on EPW data, with emphasis on shading coverage, UTCI, and MRT. The results indicate that, although the client-delivered solution complies with the evaluated parameters, the generative design alternative enhances the technical performance of the original proposal by achieving a more optimized geometry under multiple optimization criteria. The study highlights the potential of computational design in the early stages of industrial projects, improving passive performance under real technical and operational constraints.

Keywords: Generative Design; Climate Simulation; Parametric Architecture; Industrial Roof Systems; Multi-Objective Optimization.

1. INTRODUCCIÓN

En el contexto de la arquitectura industrial contemporánea, la integración de metodologías computacionales avanzadas —como el diseño generativo y las simulaciones ambientales paramétricas— ha redefinido los procesos tradicionales de toma de decisiones proyectuales. Esta investigación se sitúa dentro de dicho marco y presenta un análisis comparativo entre tres soluciones arquitectónicas orientadas a resolver el diseño de una cubierta metálica en un área semiabierta, parte de una serie de almacenes logísticos del Aeropuerto Internacional Jorge Chávez. El proyecto ejecutado tuvo como objetivo prioritario maximizar la cobertura de sombra sobre el área operativa durante la mayor parte del día, optimizando así el confort térmico y el desempeño funcional del espacio. En este contexto, el diseño de cubiertas en entornos industriales, particularmente en



zonas aeroportuarias, tiene un impacto directo en el desempeño energético de los espacios y en las condiciones de confort térmico. En climas cálidos o con alta exposición solar, una estrategia de sombreado eficiente puede reducir significativamente las cargas térmicas internas y mejorar las condiciones de operación (Chi et al., 2021). Esta investigación cobra relevancia ante la necesidad de explorar metodologías de optimización que integren simulaciones climáticas y herramientas de diseño generativo, con el objetivo de proponer soluciones arquitectónicas más eficientes y adaptadas al contexto. Para ello, se contrastaron tres propuestas: la solución original planteada por el cliente, la propuesta definitiva desarrollada por el equipo de diseño, y una tercera alternativa generada exclusivamente para esta investigación mediante un proceso de optimización multiobjetivo apoyado en diseño generativo y simulaciones energéticas en fase temprana. El objetivo general es comparar el desempeño climático y energético de estas soluciones, evaluando métricas vinculadas a la proyección de sombra, eficiencia geométrica y adecuación programática, con el propósito de valorar la eficacia del diseño generativo como metodología aplicable a la arquitectura industrial aeroportuaria.

2. METODOLOGÍA

2.1 Selección del caso de estudio

Durante el ejercicio profesional, se recibió un encargo en el estudio, un proyecto de almacenaje de distintas mercancías, transportadas mediante dollies, dentro de la zona logística del nuevo Aeropuerto Internacional Jorge Chávez, para el cual se desarrolló un espacio semiabierto, dentro de un patio de maniobras, con una cubierta a dos aguas a 11 metros de altura donde se desarrollarían las actividades. Dicho espacio, aunque cumplía con su función, tenía deficiencias en cuanto a climatización pasiva, debido a que tenía un requerimiento específico de sombra que debía aportar para cumplir su función eficientemente, esto se determinó y se corroboró mediante el desarrollo de algoritmos de simulación climática, específicamente de radiación recibida y de sombra horizontal proyectada, una de las tareas a realizar en el encargo, y el objeto de estudio de la presente investigación, fue determinar el porcentaje de sombra arrojada del diseño original, y proponer una solución que cumpla con los requerimientos de climatización pasiva para el proyecto.

El encargo se desarrolló satisfactoriamente, cumpliendo de sobremano con lo solicitado y gracias a la pericia y expertise del equipo de proyectos, usando un proceso de diseño combinado, que usa algoritmos de simulación y criterios de diseño arquitectónicos altamente eficientes, sin embargo, y dado que el presente estudio es un análisis comparativo de este caso de estudio, se propone una solución adicional, basada en los procesos de diseño multiobjetivo, y usando estrategias de diseño arquitectónico generativo, de manera tal que pueda estudiarse la eficiencia y los beneficios del uso de metodologías que fusionan el uso de herramientas de machine learning con el diseño multiobjetivo, la simulación climática y los beneficios que puede aportar el uso de estas estrategias en las etapas tempranas de un proyecto industrial.

2.2 Recolección de datos

La simulación climática, y, en especial la realizada mediante motores como Ladybugs Tools , utiliza información recolectada por distintos sensores que miden las variables climáticas locales, agrupadas en archivos. EPW (EnergyPlus Weather files), estos archivos son un compilado de datos climáticos hora por hora durante un año entero (8,760 registros)

Para la ejecución del proyecto y la presente investigación se usó como fuente el archivo EPW oficial de Ladybug Tools (Ladybug Tools LLC, s.f.) que contiene un repositorio de las distintas fuentes climáticas que proporciona EnergyPlus y que son soportadas por el motor, y con el cual se desarrollaron los algoritmos usados.




Figura 1. Archivo climático .epw

En cuanto a los modelos, en donde se realizaron las comparaciones del estudio, se desarrollaron a partir del modelo BIM del proyecto, el cual se simplificó a su mínima expresión funcional, a fin de ejecutar los análisis con la información geométrica fundamental, tanto del modelo original del proyecto, como de la solución propuesta en el estudio, adicionalmente, para objeto de esta investigación, se desarrolló una tercera opción, generada mediante algoritmos de optimización genética y análisis multiobjetivo impulsadas por machine learning (Makki, Showkatbakhsh, & Song, 2019).




Figura 2. Modelos 3D de las propuestas. Izquierda: propuesta del cliente. Derecha: Solución del estudio

2.3 Simulación inicial

Como paso inicial del estudio comparativo se establece un flujo doble de trabajo, donde se establece la geometría inicial del proyecto (modelo original) y se desglosa en parámetros modificables algorítmicamente mediante el uso de sliders dentro de Grasshopper (figura 3) de modo que se conviertan en los futuros genes que se usaran en el diseño optimizado.




Figura 3. Algoritmo de simulación inicial

Paralelamente, mediante el motor Ladybug Tools se desarrolla un algoritmo de condiciones básicas de diseño, en este caso apoyándonos de una carta psicrométrica, obtenida mediante la simulación climática, esta carta psicrométrica entrega los siguientes resultados:

Se observa un rango térmico moderado, la mayoría de puntos están entre 17 °C y 27 °C de temperatura. Esto debido a que en el eje X (horizontal) donde se observa la temperatura de bulbo seco (°C) va desde -20 °C hasta 50 °C, pero el rango real usado en Lima va de ~15 °C a ~29 °C.

Se ve además una humedad relativamente alta y constante, la mayoría de las condiciones se agrupan entre 60% y 90% de humedad relativa, esto se aprecia también en el gráfico, el eje Y (vertical derecho) muestra la humedad absoluta o relación de mezcla (kg de agua/kg de aire seco). Las curvas rojas inclinadas representan la humedad relativa (%), desde 10% hasta 100% y las líneas diagonales curvas (rojas) la entalpía (energía total del aire húmedo, en kJ/kg).

Hay una concentración densa de horas en una zona estrecha. El grupo más denso está entre 20–25 °C y 60–80% HR, con colores entre amarillo y rojo, lo que indica que el aire se encuentra en ese estado durante la mayor parte del año. Esto observado en la densidad de malla y representado mediante el mapa de calor de la misma (color azul, pocas horas; rojo, muchas horas) en la figura 4.




Figura 4. Carta Psicométrica

Además, se obtiene un análisis de viento previo, mediante la generación de una rosa de vientos, que sugiere una dirección principalmente sureste y una velocidad de viento promedio anual de 5,18 m/s (18,65 km/h o 11,6 mph) que es moderada, pero ya lo suficientemente significativa como para tener impacto arquitectónico y bio-climático (figura 5). Aunque no se realizaron simulaciones de turbulencia ni de flujo laminar para el presente estudio, se tiene en cuenta estas condiciones básicas de diseño climático para el estudio comparativo.




Figura 5. Rosa de vientos

2.4 Diseño generativo

2.4.1 Problema de diseño

El uso de la herramienta de optimización genética y análisis multiobjetivo Wallacei X requiere establecer las condiciones iniciales de diseño mediante el uso de restricciones y objetivos de diseño controlables mediante parámetros modificables (Cabel, 2023; Chi et al., 2021) para conseguir la población más optimizada genéticamente, y por ende encontrar la mejor solución para ese diseño en particular, esto dentro de la metodología de diseño generativa se denomina Problema de Diseño (Cabel, 2023).

Para este caso en particular el problema de diseño se plantea en como optimizar un complemento de una cubierta ya existente, que no suponga un costo excesivo en su fabricación, que optimice el uso final de aumentar el área de sombreado y que sea constructivamente viable. A partir de estas premisas se procede con establecer un modelo 3d parametrizable, con variables modificables en tiempo real de acuerdo a ciertos criterios de evaluación (genes), estos se optimizarán como si fuera un organismo que evoluciona con cada generación, para obtener al final la solución mejor optimizada en todas las variables (fenotipo).

2.4.2 Definición de los genes

Como primera restricción se estableció minimizar el costo de construcción, esto se tradujo en una condición que limite la cobertura a su área mínima de funcionamiento, al ser una cobertura a dos aguas libre es sus cuatro frentes, la condición se cumple al sumar el área de cada de cada cubierta adicional y obtener un promedio general, para no limitar las iteraciones del algoritmo evolutivo se establece un rango inferior mínimo, con relación directa del área mínima proyectada que tiene que ser mayor que el área recta proyectada de la cubierta original (área promedio de la proyección horizontal de cubiertas + área de la proyección horizontal de la cubierta >área de la proyección horizontal de la cubierta)

Debido a que no se tiene en cuenta la materialidad de la nueva cubierta ni los costos de construcción/fabricación, la variable toma este resultado como indicador indirecto, suponiendo que a menor área de construcción se incurre en un menor costo.

La segunda restricción permite que el modelo proyecte en el plano horizontal una geometría cuya área sea tal que sumado al área de la proyección original se mucho mayor, maximizando así el área sombreada; así, la máxima área proyectada se calcula proyectando horizontalmente cada plano de cubierta, y esto sumándolo al área proyectada original.

La tercera restricción responde al proceso constructivo y al correcto drenaje de aguas pluviales en la cubierta. Una pendiente adecuada garantiza que el agua de lluvia sea evacuada eficientemente, evitando acumulaciones que pueden generar filtraciones, sobrecargas estructurales o degradación prematura del sistema constructivo. Además, muchas normativas técnicas como el Reglamento Nacional de Edificaciones, códigos internacionales o especificaciones de fabricantes establecen valores mínimos de pendiente según el tipo de material de cubierta y la longitud de escurrimiento.

En el presente estudio, se incorpora como variable de análisis la inclinación relativa de los paneles. Para cuantificar la inclinación, se utiliza un parámetro geométrico relativo basado en el producto escalar entre el vector normal de cada panel (n) y el vector unitario del eje vertical (eje Z)

$$\theta = \arccos(n \cdot z) \quad (1)$$

Donde:

θ : ángulo de inclinación del panel

n : vector normal del panel

z : vector unitario del eje vertical

La desviación angular resultante se normaliza en un rango de 0 a 1 (expresado de 0% a 30% en la escala del estudio), donde 0% representa la horizontalidad absoluta. El límite del 30% se define para garantizar la eficiencia geométrica del modelo, evitando ángulos que conlleven cálculos de complejidad innecesaria o que representen resultados similares con formas geométricas más simples. Esta medida no corresponde a una pendiente normativa en sentido estricto, sino que se utiliza como parámetro geométrico interno para evaluar y comparar morfologías de cubierta en función de su grado de inclinación.

La elección de esta variable responde a la necesidad de cuantificar el comportamiento espacial de paneles con geometrías no convencionales, donde el diseño no depende exclusivamente de pendientes estructurales o de

evacuación de agua, sino también de factores como la captación solar, la ventilación, el control de sombras o criterios estéticos.

Como última restricción, se incorpora la flecha o deflexión como variable estructural clave para la evaluación de desempeño de los elementos de cubierta propuestos. Según Hibbeler (2020) esta variable puede definirse como la deformación vertical máxima que puede presentar un elemento sometido a carga, una flecha admisible como la variable utilizada, define la fuerza que deforma al elemento sin comprometer su integridad estructural, funcionalidad ni percepción estética. Su valor se expresa comúnmente como una fracción de la luz libre del elemento (L/n), de acuerdo con los criterios establecidos en normativas técnicas de diseño estructural, dependiendo del tipo de material y del uso previsto de la estructura.

Esta restricción estructural asegura la viabilidad técnica del sistema, garantizando un comportamiento seguro y predecible ante cargas gravitacionales o ambientales.

Al no evaluar directamente un material en particular para este estudio se utiliza la fórmula comparativa de pre dimensionamiento:

$$\text{Flecha Máxima}(\delta) = f \cdot x^{-3} \leq \frac{1}{200} \quad (2)$$

Donde:

f: módulo del material (5×10^{-3})

x: luz vertical del modelo

$L/200$: flecha admisible mínima




Figura 6. Problema de diseño, definición de genes

2.4.3 Ejecución del algoritmo generativo

Para la ejecución del algoritmo se usó como configuración la siguiente: un tamaño de generación: 50 individuos por generación en un número total de 100 generaciones, dando un tamaño total de la población evaluada de 5000 soluciones.

Como parámetros del algoritmo se configuró una probabilidad de cruce (crossover) de 0,9; una probabilidad de mutación $1/n$, un índice de distribución del cruce (crossover distribution index) de 20, un índice de distribución de la mutación (mutation distribution index) de 20 y una semilla aleatoria (random seed): 1 (para asegurar reproducibilidad).

Como parámetros de la Simulación se establecieron 3 genes agrupados en dos sliders (variables de entrada) con una cantidad total de valores posibles (combinaciones de sliders): 387, dentro de un número de funciones objetivo (fitness) de 4, dando como resultado un tamaño del espacio de búsqueda: $1,3 \times 10^4$ posibles soluciones. Se utilizaron el software Rhinoceros 7,4, el complemento de grasshopper Wallacei X 2,7. Las simulaciones fueron ejecutadas en un equipo con procesador Intel Core i7-13620H (2.4 Hz), 24 GB de memoria RAM y tarjeta gráfica NVIDIA RTX 4060 (6 GB VRAM), bajo sistema operativo Windows 11 Pro de 64 bits, con tiempos de simulación de 8 segundos por hijo aproximadamente.




Figura 7. Izquierda: Configuración de entrada. Derecha: Espacio objetivo de búsqueda

2.4.4 Análisis computacional de desempeño y optimización final

El análisis de las 5000 soluciones entregadas se hizo mediante un proceso de machine learning, utilizando el algoritmo K-means, integrado en el motor de Wallacei, adicionalmente se evaluaron los resultados de cada restricción observando su comportamiento y tendencia mediante el análisis de su desviación estándar, una análisis de la fluctuación de sus valores de restricción y la tendencia de las generaciones por restricción, siendo el resultado del análisis 41 soluciones perfectamente elegibles, que cumplieran con el balance adecuado de todas las restricciones.




Figura 8. Análisis estadístico de soluciones

Luego de que el algoritmo entregara estas soluciones, se utilizó, nuevamente el algoritmo de aprendizaje no supervisado para analizar estas últimas, agrupadas en 10 clústeres, obteniendo así 10 soluciones especializadas, las cuales se analizaron en una tabla de ponderación donde se incluyeron los valores de la desviación estándar, los valores objetivo, la tendencia de la desviación estándar, la tendencia de objetivo y el fenotipo (modelo 3d) de la solución, esto, particularmente importante, debido a que como cualquier algoritmo evolutivo multiobjetivo, trata el resultado del diseño como un conjunto de variables puramente matemáticas, dejando de lado la propuesta visual o factibilidad constructiva (aunque incluir variables como flecha admisible y pendiente limitan encontrar soluciones completamente inviables) obteniendo como solución escogida, dentro del universo de búsqueda al individuo 37 de la generación 26.

Tabla 1. Resumen de Clasificación de Soluciones

Solución	Desv. Estándar	Valores Objetivo	Tendencia D.E.	Tendencia Objetivo	Modelo 3D	Resultado
Gen 22 Ind 22	SI	NO	SI	SI	NO	INVARIABLE
Gen 13 Ind 11	SI	NO	SI	SI	NO	VIALE (S. ELEGIDA)
Gen 26 Ind 37	SI	SI	SI	SI	SI	INVARIABLE
Gen 27 Ind 48	SI	SI	SI	SI	NO	VIALE
Gen 52 Ind 43	SI	NO	SI	SI	SI	INVARIABLE
Gen 43 Ind 28	SI	SI	SI	SI	NO	INVARIABLE
Gen 41 Ind 30	SI	NO	SI	SI	NO	INVARIABLE
Gen 0 Ind 17	NO	SI	SI	SI	NO	INVARIABLE
Gen 41 Ind 48	SI	NO	SI	SI	NO	INVARIABLE
Gen 15 Ind 47	SI	NO	SI	SI	NO	INVARIABLE

Así, el fenotipo elegido muestra un equilibrio entre las variables analizadas de sus genes y la volumetría 3d resultante.




Figura 9. Solución optimizada

2.5 Evaluación comparativa

Una vez seleccionadas las opciones de diseño a comparar, se procedió a hacer un cuadro con datos con los cuales hacer un análisis objetivo. Durante la entrega del encargo al cliente del proyecto, se usó una tabla comparativa donde se analizaba el porcentaje de sombra proyectada y el área sombreada en metros cuadrados en dos fechas claves representativas: 19 de enero para el verano y 23 de septiembre para la primavera, dentro de estas fechas se analizaron además los resultados para horas de exposición solar representativas; desde las 6:00 horas hasta las 18:00 horas, con intervalos de 1 hora.

Para el desarrollo de la presente investigación, se adicionaron dos indicadores adicionales: el Índice universal de Clima Térmico (UTCI) definido como un índice térmico universal que representa el estado térmico equivalente del cuerpo humano calculado a partir del balance energético fisiológico, considerando variables ambientales reales como temperatura del aire, viento, humedad, radiación (Matzarakis, Muthers, & Rutz, 2014) y la Temperatura Radiante Media (MRT) que puede entenderse como una temperatura única equivalente que representa el efecto combinado de todas las fuentes de radiación presentes en el entorno, que interactúan sobre el cuerpo humano (Guo et al., 2020) para tener un espectro completo de análisis de desempeño medioambiental bajo estrategias de diseño pasivas.

3. RESULTADOS Y DISCUSIÓN

Los resultados obtenidos del análisis de la presente investigación muestran una clara mejora en el desempeño climático de las opciones propuestas (la opción propuesta por el estudio de diseño y la opción optimizada de esta investigación) contra el diseño original durante las fechas y horas de análisis.

En la petición original del proyecto (análisis de sombra) se muestra una clara ventaja de las propuestas siendo los valores mínimos de porcentaje de sombras en el verano, a las 6:00 horas con valores de 5,43% para el diseño original y un valor de 0,23% para la propuesta del estudio y 5.43% para la propuesta optimizada y a las 18:00 horas con 8,19% para el diseño original y propuesta optimizada y 35,39% para la propuesta del estudio, unos picos altos alcanzados entre las 12:00 y 14:00 horas, donde la propuesta optimizada alcanza valores del 100% de sombras.




Figura 10. Porcentaje de sombra en verano

Para la primavera, la propuesta del estudio muestra ventaja desde las primeras horas (7:00 horas) siendo superada por la propuesta optimizada sobre las 10:00 horas hasta las 14:00 horas, donde sus valores decrecen hacia las 18:00, manteniendo una correlación con las fechas analizadas en verano.




Figura 11. Porcentaje de sombra en primavera

En cuanto al indicador de UTCI, aunque todas las propuestas se encuentran en el rango de operación confortable, salvo ciertas horas, donde se presenta un calor moderado, la propuesta del estudio y la propuesta optimizada muestran ventaja sobre la propuesta original, manteniéndose en valores intermedios en relación a los rangos establecidos por el UTCI; teniendo los mejores valores en verano la solución propuesta por el estudio, sobre las 9:00 horas y hasta el final, manteniendo los valores más consistentes, entre los 22° C y los 25°C, teniendo los valores más críticos a las 11:00 horas, donde la propuesta original (28,68° C) y la solución optimizada (27,25°C) fallan, teniendo un ligero aumento del estrés térmico solución del estudio (26,64°C) aunque manteniéndose estas últimas más estables en horarios de mayor radiación solar, y dentro de los parámetros aceptables, mostrando la solución del estudios reducciones de hasta 2,5°C, haciendo la propuesta más confortable.




Figura 12. Temperatura UTCI en verano

En primavera, las tres soluciones presentan valores aceptables, siendo la solución original y la solución optimizada las que presentan los valores más estables a lo largo de todas las horas analizadas, ubicándose en los rangos intermedios de los valores confortables, encontrándose con temperaturas promedio de 22°C y 23°C, teniendo la solución propuesta por el estudio reducciones de hasta 3,5°C, presentando los mejores valores.




Figura 13. Temperatura UTCI en primavera

En cuanto a los valores de la Temperatura Radiante Media, se tienen valores altos en verano, iniciando cerca de los 21°C a las 6:00 y llegando alrededor de los 47°C al medio día (12:00) empezando a descender a las 13:00 horas, lo que indica la eficiencia de las propuestas diseñadas, cerrando cerca de los 24°C a las 18:00. Como resultado se tiene que el modelo original presenta mayores valores de estrés térmico, lo que se relaciona directamente con los valores obtenidos de UTCI, la propuesta del estudio presenta mejor comportamiento, reduciendo el MRT hasta 8°C, seguida de la solución optimizada, que reduce hasta 4°C.




Figura 14. Temperatura MRT en verano

En relación a los valores medidos en primavera, se tienen valores más bajos que en el verano, con los valores más bajos de 13°C y los más altos de hasta casi 37°C, siendo la propuesta del estudio la que tiene valores mejor distribuidos a lo largo del día, con valores de hasta casi 30°C en las horas más críticas, teniendo una reducción de 7°C en comparación con el modelo original, que, incluso en temperaturas más bajas que en verano, presenta un aumento del estrés térmico, seguida de la solución optimizada, que aunque su reducción es menor, presenta más estables y reducidos por más horas (desde las 10:00 hasta las 14:00 principalmente). Finalmente, a las 18:00 se muestra una inversión del MRT, teniendo la propuesta original el menor valor, siendo la solución optimizada la que presenta un valor más estable, seguida de la propuesta del estudio.




Figura 15. Temperatura MRT en primavera

La capacidad de las dos soluciones mejoradas (propuesta del estudio y solución generativa) para incrementar el porcentaje de sombra en horas de máxima radiación solar confirma el valor del diseño paramétrico y la optimización multiobjetivo. Mientras que el diseño original alcanzaba un mínimo de 5,43 % de sombreado a las 6:00 h en verano, la solución generativa logró cubrir hasta el 100 % en el pico de mediodía, lo cual supone una mejora drástica en la protección térmica pasiva.

En el análisis del UTCI se muestra reducciones de estrés térmico de hasta 2,5 °C en la propuesta del estudio y de hasta 1,4 °C en la solución optimizada respecto al diseño original. Esta diferencia tiene un impacto significativo en la percepción de confort. La ligera superioridad de la propuesta del estudio sugiere que la incorporación de criterios cualitativos complementa el rigor cuantitativo del algoritmo, en tanto, las reducciones de MRT de hasta 8 °C (propuesta del estudio) y 4 °C (solución optimizada) implican una menor ganancia de calor por radiación directa e indirecta. La geometría generativa distribuye la sombra de modo más uniforme, lo cual es deseable en espacios donde la uniformidad del confort es más crítica.




Figura 16. Visualización de Resultados. Arriba: Porcentaje de sombras. Abajo: Distribución UTCI

En cuanto a las implicaciones prácticas del estudio, la integración de simulación climática y diseño generativo en fases preliminares permite descartar rápidamente configuraciones poco eficientes y concentrar esfuerzos en unas pocas alternativas de alto desempeño.

Al mejorar el confort pasivo, se puede reducir la necesidad de sistemas de climatización mecánicos (Fernández, 2021) lo que puede traducirse en disminución de costos operativos y emisiones de CO₂ a lo largo de la vida útil de la cubierta, sin embargo, hay que destacar que los estudios de climatización mecánica y la implementación de sistemas HVAC sigue siendo a día de hoy un pilar fundamental en el diseño y operación de proyectos industriales, el presente estudio hace hincapié en la necesidad de reducir, siempre que se pueda, la necesidad de la utilización de estos equipos y su reemplazo por soluciones pasivas, a fin del compromiso de reducir la huella de carbono, que, es bien sabido, en la industria de la construcción en general, sigue siendo grande.

Realizar estudios de simulación climática en fases iniciales de un proyecto permite anticipar el comportamiento frente a condiciones ambientales reales y extremas, la simulación climática recrea artificialmente factores como temperatura, humedad o radiación solar, lo que ayuda a anticipar cómo reaccionarán los elementos proyectados y tomar decisiones respecto a este comportamiento (Han, 2018)

El diseño generativo, por su parte, explora cientos de soluciones de diseño simultáneamente bajo múltiples criterios (peso, rigidez, sostenibilidad, etc.). Al integrar simulación física temprana (estructural, térmica, aerodinámica, etc.) en este proceso, se asegura que “todos los elementos físicos importantes para el proyecto se consideren desde el inicio

Este enfoque incorpora beneficios como:

Reducción de costos y materiales: el diseño generativo tiende a eliminar material sobrante optimizando la geometría. Por ejemplo, puede diseñar una pieza con menos material sin sacrificar su resistencia estructural

Innovación y rendimiento: integrar desde el inicio la simulación en el diseño abre puertas a soluciones innovadoras. Al poder manejar múltiples objetivos (por ejemplo, rigidez, coste, confort), el proceso generativo con simulación acelera la búsqueda de configuraciones óptimas en el frente de Pareto. Como describe Swearingen (2023), el diseño generativo y la simulación transforman exigencias complejas en oportunidades de innovación, asegurando que desde la fase conceptual se satisfagan todos los requisitos físicos.

Exploración de soluciones controlada: La metodología, por su naturaleza evolutiva, es abierta y puede ser adaptada para operar con restricciones y enfoques ilimitados (Cabel, 2023) lo que vuelve al diseño generativo una herramienta capaz de adaptarse a cualquier tipo de proyecto.

La metodología de parametrización, simulación y optimización es transferible a otros proyectos industriales que requieran soluciones de sombra y confort térmico particulares de operación, tanto en espacios abiertos, semi abiertos y cerrados, el uso de esta metodología, tanto de diseño generativo como de simulación climática

es transversal al diseño, permite tener en cuenta al usuario final en su operación y tener un panorama más completo y amplio de soluciones, que, con la metodología tradicional, muchas veces se dejan de lado.

Limitaciones

A continuación, se detallan las principales limitaciones identificadas en el desarrollo de esta investigación, agrupadas por categorías metodológicas, técnicas y prácticas:

Limitaciones Metodológicas

- Simulación climática unidireccional: El análisis se basó en un único archivo EPW representativo de Lima (2024), sin considerar variaciones interanuales, eventos climáticos extremos (ENSO) ni microclimas locales como islas de calor urbanas o efectos de reflexión en patios industriales. De acuerdo a lo descrito por Tumini e Higuera-García (2013) el promedio de los datos de entrada y salida de los archivos climáticos varían dependiendo del software con el que son compatibles, sin embargo, son aceptados para cálculos de simulación para las primeras etapas de diseño.
- Ausencia de validación empírica: No se realizó monitoreo in situ de UTCI, MRT ni percepción de confort con usuarios reales, limitando la correlación entre resultados simulados y experiencia operativa real.
- Criterios multiobjetivo simplificados: La optimización generativa priorizó sombra/UTCI sin integrar ciclo de vida completo de materiales ni análisis económico detallado (costo-beneficio HVAC reducido).

Limitaciones Técnicas y Normativas

- Proxy área cubierta: Se asumió como indicador costo, ignorando variaciones materiales (acero vs composite), logística montaje y mantenimiento.
- Las variables de pendiente y deflexión se emplearon de forma genérica (0–30 % y L/n, respectivamente) sin ajustarse a normativas específicas de materiales ni condiciones de pendiente mínima según RNE como E.020 (cargas) E.090 (estructuras metálicas) A.010 (condiciones generales de diseño) o especificaciones técnicas de fabricantes, el uso de estas variables es simplificado y orientado a un pre dimensionamiento, la solución final debe pasar por un estudio estructural formal, basado en normas de ingeniería y normativa de construcción local para poder usarse en fases de construcción y fabricación.

Limitaciones de Alcance y Escalabilidad

- Contexto proyecto específico: Análisis limitado a cubierta industrial particular; transferibilidad a espacios semiabiertos/cerrados requiere recalibración parámetros.
- Dependencia tecnológica: Diseño generativo demanda software propietario (Rhino/Grasshopper) y competencias avanzadas, limitando replicabilidad en firmas de pequeño y mediano alcance.
- Sesgos algorítmicos: Los parámetros iniciales pueden sesgar hacia soluciones formalmente complejas, económicamente inviables sin validación constructiva. Es responsabilidad de los proyectistas seleccionar la solución más compatible además con criterios técnicos, proyectuales, arquitectónicos y coherentes con el entorno y proyecto específico.

Estas limitaciones posicionan el estudio como prototipo metodológico validado numéricamente, sugiriendo investigaciones futuras con validación campo.

4. CONCLUSIONES

Aunque la propuesta entregada por el estudio cumple notablemente con los indicadores analizados en esta investigación —en parte gracias a la experticia de los diseñadores y arquitectos involucrados—, es importante destacar el valor del análisis climático temprano y de metodologías de diseño no convencionales, como aquellas basadas en aprendizaje no supervisado. Estas permiten explorar soluciones que, de otro modo, podrían no haberse considerado en las etapas iniciales del proyecto.

La propuesta desarrollada en el marco de esta investigación, mediante diseño generativo computacional, demuestra que la incorporación de tecnologías y procesos de diseño emergentes basados en restricciones puede aportar transparencia al proceso proyectual. Esto se logra al visibilizar variables clave que influyen directamente en la geometría final del edificio y en su comportamiento dentro del entorno en el que se inserta, condicionando así su funcionalidad y la experiencia del usuario final.

Asimismo, el uso de simulaciones energéticas en fases tempranas del diseño proporciona una base sólida para la toma de decisiones en torno al comportamiento térmico, la geometría y el desempeño ambiental del proyecto. Los datos obtenidos son esenciales para análisis posteriores, tales como el cálculo de cargas de HVAC, el diseño integrado de sistemas que optimicen el rendimiento energético del edificio, y la validación de decisiones arquitectónicas bajo criterios de eficiencia y sostenibilidad ambiental.

Aunque los indicadores usados en la presente investigación responden a los requerimientos de confort y sombra exigidos por los clientes, el uso de simulaciones permite también analizar más variables relacionadas con el confort y eficiencia energética. El uso de algoritmos de simulación permite visualizar variables tempranas importantes como cantidad de radiación recibida, tiempo de exposición solar, que pueden ser útiles en estudios tempranos de ubicación de paneles solares y de la energía teórica que podrían producir.

Finalmente, el uso de un motor generativo multiobjetivo, y la geometría de la propuesta obtenida abre la puerta a estudiar la eficiencia aerodinámica del proyecto, que, aunque la ubicación geográfica del mismo, no lo hace relevante, puede ser una variable a tener en cuenta para estudios posteriores en proyectos similares.

REFERENCIAS BIBLIOGRÁFICAS

- Cabel, J. (2023). Diseño Generativo para el Centro de I+D de la Sede Regional de IMARPE Huanchaco. *SCIÉND0*, 26(2), 133–138.
- Chi, D. A., González M., E., Valdivia, R., & Gutiérrez J., E. (2021). Parametric design and comfort optimization of dynamic shading structures. *Sustainability*, 13(14), 7670. <https://doi.org/10.3390/su13147670>
- Fernández Gómez, J. (2021). Eficiencia energética en el sector industrial (Cuadernos Orkestra, 02/2021). Orkestra - Instituto Vasco de Competitividad, Fundación Deusto. <https://www.orkestra.deusto.es/images/investigacion/publicaciones/informes/cuadernos-orkestra/210005-Eficiencia-Energ%C3%A9tica-Sector-Industrial-INFORME-COMPLETO-.pdf>
- Guo, H., Aviv, D., Loyola, M., Teitelbaum, E., Houchois, N., & Meggers, F. (2020). On the understanding of the mean radiant temperature within both the indoor and outdoor environment, a critical review. *Renewable and Sustainable Energy Reviews*, 117(109207), 109207. <https://doi.org/10.1016/j.rser.2019.06.014>
- Han, T., Huang, Q., Zhang, A., & Zhang, Q. (2018). Simulation-based decision support tools in the early design stages of a green building—A review. *Sustainability*, 10(10), 3696. <https://doi.org/10.3390/su10103696>
- Hibbeler, R. C. (2020). Structural analysis (10th ed., SI Units). Pearson Education, Inc
- Ladybug Tools LLC. (s.f.). EPW map. Ladybug Tools. <https://www.ladybug.tools/epwmap>
- Makki, M., Showkatbakhsh, M., & Song, Y. (2019). Wallacei Primer 2.0 [Manual]. Wallacei. <https://www.wallacei.com/>
- Matzarakis, A., Muthers, S., & Rutz, F. (2014). Application and comparison of UTCI and PET in temperate climate conditions. *Finisterra*, 49(98), 21–31. <https://doi.org/10.18055/Finis6453>
- Rhino Plugin. (s/f). Pollination.solutions. Recuperado el 3 de agosto de 2025, de <https://www.pollination.solutions/rhino-plugin>.
- Swearingen, C. (2023). Innovating Sustainability with Generative Design. SME (Society of Manufacturing Engineers). <https://www.sme.org/technologies/articles/2023/june/innovating-sustainability-with-generative-design>
- Tumini, I., & Higuera García, E. (2013). Alcances y limitaciones de las herramientas de simulación para el estudio del microclima urbano. *Dyna energía y sostenibilidad*, 2(3), [17 p.]-[17 p.]. <https://doi.org/10.6036/es6921>

ANEXOS




Figura 17. Algoritmo de Optimización




Figura 18. Algoritmo de Análisis




Figura 19. Ejemplo de Solución Exportada




Figura 20. Resultados de Soluciones Optimizadas

Tabla 2. Porcentaje de Sombra en verano

FECHA	HORA	MODELO ORIGINAL	SOLUCIÓN ESTUDIO	SOLUCIÓN OPTIMIZADA
19 - ENE	06:00	5,43	0,23	5,43
	07:00	5,56	29,36	5,56
	08:00	19,73	56,29	37,72
	09:00	44,19	72,09	64,63
	10:00	63,04	82,14	84,35
	11:00	77,66	88,53	96,67
	12:00	91,51	96,48	100,00
	13:00	89,18	96,22	100,00
	14:00	80,72	92,43	93,89
	15:00	65,18	85,54	83,42
	16:00	45,51	76,26	67,55
	17:00	11,78	59,75	32,49
	18:00	8,19	35,39	8,19

Tabla 3. Porcentaje de Sombra en primavera

FECHA	HORA	MODELO ORIGINAL	SOLUCIÓN ESTUDIO	SOLUCIÓN OPTIMIZADA
23 - SET	06:00	6,24	1,51	6,24
	07:00	6,25	43,20	6,25
	08:00	27,15	65,23	47,54
	09:00	54,17	79,22	75,68
	10:00	73,64	88,80	89,51
	11:00	84,66	92,90	98,16
	12:00	87,36	92,71	100,00
	13:00	80,76	91,31	97,17
	14:00	66,27	84,37	87,38
	15:00	48,76	75,82	70,00
	16:00	26,35	63,14	44,87
	17:00	6,86	42,71	7,66
	18:00	7,06	3,97	7,06

Tabla 4. Temperatura en °C UTCI en verano

FECHA	HORA	MODELO ORIGINAL	SOLUCIÓN ESTUDIO	SOLUCIÓN OPTIMIZADA
19 - ENE	06:00	21,94	22,06	21,75
	07:00	21,72	21,33	21,49
	08:00	25,03	24,11	24,50
	09:00	26,63	25,10	26,36
	10:00	28,00	26,20	26,97
	11:00	28,68	26,64	27,25
	12:00	27,84	25,81	26,70
	13:00	26,62	24,68	25,54
	14:00	25,56	23,67	24,49
	15:00	25,16	23,52	24,22
	16:00	23,81	22,66	23,15
	17:00	21,17	20,50	20,78
	18:00	19,85	19,72	19,78

Tabla 5. Temperatura en °C UTCI en primavera

FECHA	HORA	MODELO ORIGINAL	SOLUCIÓN ESTUDIO	SOLUCIÓN OPTIMIZADA
23 - SET	06:00	16,09	16,27	16,19
	07:00	18,68	18,00	18,26
	08:00	20,71	19,39	19,94
	09:00	22,88	20,88	21,73
	10:00	23,97	21,60	22,62
	11:00	23,86	21,49	22,51
	12:00	20,75	18,60	19,52
	13:00	18,25	16,25	17,10
	14:00	18,61	16,79	17,54
	15:00	15,10	13,42	14,09
	16:00	14,59	13,41	13,86
	17:00	11,75	11,12	11,33
	18:00	10,07	10,51	10,32

Tabla 6. Temperatura en °C MRT en verano

FECHA	HORA	MODELO ORIGINAL	SOLUCIÓN ESTUDIO	SOLUCIÓN OPTIMIZADA
19 - ENE	06:00	20,87	21,28	22,99
	07:00	25,70	24,32	24,88
	08:00	30,95	27,66	29,04
	09:00	38,26	32,60	36,93
	10:00	42,88	35,90	38,88
	11:00	45,69	37,73	40,02
	12:00	47,54	39,25	42,87
	13:00	46,91	38,85	42,37
	14:00	46,30	38,44	41,84
	15:00	43,59	36,70	39,63
	16:00	37,93	33,13	35,15
	17:00	31,13	28,48	29,59
	18:00	24,32	23,84	24,05

Tabla 7. Temperatura en °C MRT en primavera

FECHA	HORA	MODELO ORIGINAL	SOLUCIÓN ESTUDIO	SOLUCIÓN OPTIMIZADA
23 - SET	06:00	13,61	14,12	13,89
	07:00	20,28	18,31	19,07
	08:00	25,58	21,70	23,29
	09:00	31,97	25,92	28,46
	10:00	36,01	28,65	31,75
	11:00	36,87	29,39	32,55
	12:00	36,98	29,94	32,92
	13:00	35,77	29,16	31,93
	14:00	35,07	28,98	31,47
	15:00	32,82	27,25	29,48
	16:00	28,14	24,27	25,73
	17:00	23,36	21,25	21,95
	18:00	14,06	15,50	14,86