

EDIFICIOS COMO REDES: DISEÑO GENERATIVO BASADO EN GRAFOS PARA SISTEMAS MODULARES 3D DE VIVIENDA INDUSTRIALIZADA

Asier Urueña¹, Sarah Noyé², Iñigo Uribarri³, Asier Garmendia⁴, José Manuel Baraibar⁵

¹ TECNALIA RESEARCH & INNOVATION, Derio, España, asier.urueña@tecnalia.com

² TECNALIA RESEARCH & INNOVATION, Derio, España, sarah.noye@tecnalia.com

³ TECNALIA RESEARCH & INNOVATION, Derio, España, inigo.uribarri@tecnalia.com

⁴ TECNALIA RESEARCH & INNOVATION, Derio, España, asier.garmendia@tecnalia.com

⁵ VIUDA DE SAINZ, Abanto-Zierbena, España, jmbaraibar@viudadesainz.com

Resumen

Este trabajo presenta los avances de VDS en el marco del proyecto TAMESIS en el ámbito del diseño generativo con redes neuronales de grafos (GNN). El caso de uso es la adaptación de proyectos arquitectónicos convencionales al sistema modular 3D EKONSTEAM de JIT Housing/VDS: módulos de acero con restricciones dimensionales y de adyacencia estrictas que deben compatibilizarse con exigencias normativas y con el programa habitacional.

Un edificio no es únicamente geometría: es un sistema interconectado de espacios, componentes y relaciones funcionales. Esta perspectiva, que sitúa al edificio como una *red de conocimiento*, abre una vía natural hacia el diseño generativo basado en grafos. Cuando la topología de un edificio (qué estancias existen, cómo se conectan, qué función cumplen) se representa mediante un grafo (nodos = estancias, aristas = adyacencias), se crea la estructura de datos idónea tanto para analizar edificios existentes como para generar nuevas propuestas de manera automática.

El enfoque desarrollado combina la representación en grafo de planos de planta con modelos generativos de difusión aprendidos a partir del dataset público Modified Swiss Dwellings (MSD), que contiene más de 5.300 plantas completas y 15.900 apartamentos anotados. Se han explorado y comparado tres familias de métodos: heurísticas clásicas, modelos variacionales (VGAE) y modelos de difusión sobre grafos, habiendo desarrollado un modelo de difusión de aproximadamente 19 millones de parámetros orientado al condicionamiento por contorno de edificio.

El principal resultado es un demostrador web funcional que permite a técnicos de diseño generar y comparar múltiples alternativas de distribución modular en segundos. La estimación del impacto, cuando los modelos generativos se integren completamente, apunta a una reducción del 50% en el tiempo de diseño detallado, contribuyendo a uno de los objetivos de VDS de mejorar la productividad del sector en más de un 30% para 2029.

Palabras clave: diseño generativo, grafos de conocimiento, construcción industrializada

1 Introducción

1.1 El reto de la vivienda industrializada en altura

La industrialización de la construcción residencial en altura es una prioridad estratégica en España y especialmente en Euskadi. El ecosistema industrial vasco dispone ya de capacidad productiva en sistemas 3D modulares de acero, como los módulos EKONSTEAM desarrollados por JIT Housing y

VDS Viuda de Sainz, que han participado en proyectos piloto de vivienda protegida promovidos por VISESA y que se posicionan como solución en la modalidad «Módulos 3D Acero» del diálogo competitivo de Sopela-Asua [1].

Sin embargo, la adaptación de un proyecto arquitectónico convencional a las condiciones del sistema modular (dimensionales, constructivas y normativas) es hoy un proceso manual, iterativo y costoso en tiempo de ingeniería. Con objetivos de VISESA de 500 viviendas protegidas al año y la necesidad de compatibilizar industrialización, sostenibilidad y flexibilidad tipológica, se hace imprescindible desarrollar herramientas de apoyo al diseño que acorten los ciclos de iteración entre promotor y fabricante.

El proyecto TAMESIS (2024), se conformó para el objetivo general de investigación en tecnologías físicas y digitales avanzadas para la industrialización de sistemas constructivos. Este proyecto fue financiado por el Gobierno Vasco en el marco del programa HAZITEK.

En el contexto de TAMESIS, VDS (Viuda de Sainz) con participación de JIT Housing y el apoyo de Tecnalía como centro tecnológico de la Red Vasca de Ciencia, Tecnología e Innovación (RVCT) investiga el uso de GNN y modelos de difusión para adaptar proyectos arquitectónicos convencionales a soluciones modulares 3D industrializadas, con compatibilidad BIM.

1.2 El edificio como red de conocimiento

La representación digital de los edificios ha estado dominada históricamente por modelos geométricos, desde el dibujo vectorial hasta el BIM tridimensional. Sin embargo, un edificio no es únicamente un conjunto de sólidos y superficies: es un sistema interconectado de objetos, espacios y personas cuyas relaciones funcionales determinan tanto su habitabilidad como su lógica constructiva [2].

Esta perspectiva ha encontrado en los *grafos* su expresión formal más potente. Un grafo $G = (V, E)$ en el que los nodos V representan entidades (estancias, componentes, sistemas) y las aristas E representan las relaciones entre ellas (adyacencia, paso, jerarquía funcional) permite capturar simultáneamente la conectividad y la semántica de un edificio de un modo que los modelos puramente geométricos no pueden. Los grafos codifican qué espacios hay, cómo se accede de unos a otros, cuál es el espacio central de circulación, qué zonas forman comunidades funcionales. Esto se ilustra en la Figura 1, donde se muestra un plano de planta residencial (izquierda) y su representación como grafo espacial (derecha). Cada nodo representa una estancia, cada arista una conexión funcional y el tamaño del nodo el área relativa de la estancia [3].




Figura 1. Dualidad geometría/topología

Trabajos recientes en el dominio AECO (Architecture, Engineering, Construction and Operation) han demostrado que esta representación es suficientemente rica como para inferir automáticamente el tipo de uso de cada estancia (dormitorio, salón, cocina, baño) con una precisión superior al 86%, combinando métricas morfológicas y topológicas derivadas del grafo espacial de la planta [4].

Esta capacidad analítica sustenta una de las hipótesis centrales del presente trabajo: si un grafo puede *representar* un edificio existente, también puede ser la base para *generarlo*. Pasar de la representación analítica al diseño generativo es el salto que explora VDS en esta línea de investigación.

2 Condicionantes del diseño modular

El sistema modular EKONSTEAM impone un conjunto de condicionantes que delimitan el espacio de soluciones válidas para cualquier propuesta de diseño.

Los módulos EKONSTEAM cuentan con una anchura máxima de 4,45 m y una longitud de entre 9,0 y 9,5 m, con una altura libre entre plantas de 3,1 m. Los corredores son elementos independientes que discurren fuera de los módulos, mientras que las terrazas pueden integrarse en el volumen del módulo o configurarse como voladizos exteriores.

La normativa aplicable varía según la comunidad autónoma. En el País Vasco, el D80/2022 establece superficies mínimas con criterio ECK (Estar-Comedor-K/Cocina) incremental, mientras que en Madrid el PGOU exige que la habitación principal tenga al menos 12 m² y las secundarias al menos 7 m². La orientación del edificio impone restricciones adicionales sobre la posición de las estancias principales, que pueden distribuirse desde tipologías de una sola orientación en corredor hasta esquinas con tres orientaciones posibles.

Las decisiones de diseño añaden una tercera capa de condicionantes. Los proyectos EKONSTEAM deben respetar la zonificación funcional noche/día, agrupando los dormitorios en una zona separada de las estancias de día, concentrar los núcleos húmedos para optimizar las instalaciones, minimizar los espacios de paso y garantizar que cada apartamento sea divisible en módulos independientes con interfaces constructivas compatibles entre sí. La Figura 2 resume estas tres capas de forma esquemática.

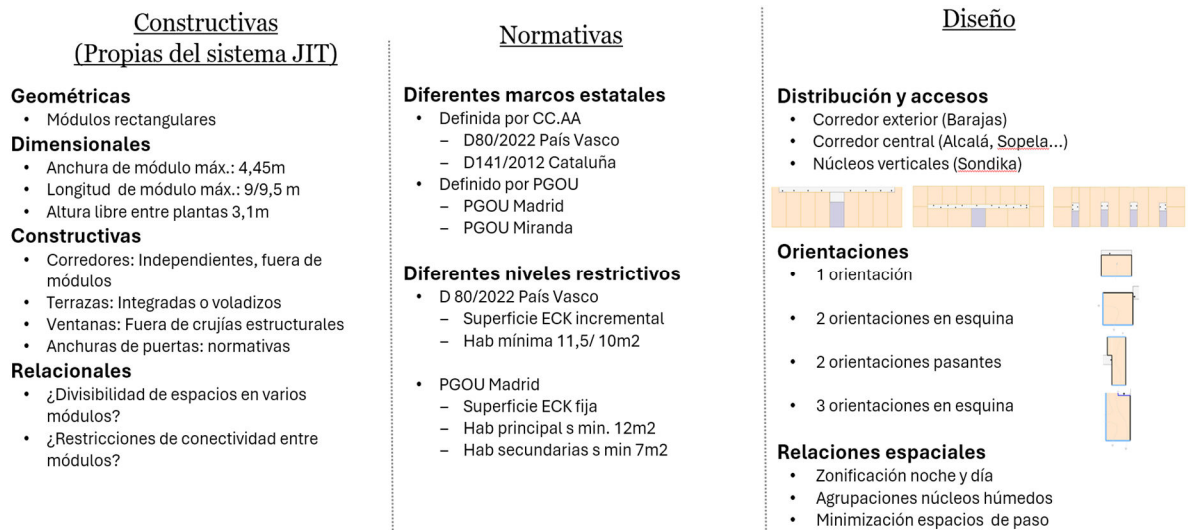


Figura 2. Taxonomía de condicionantes

Estas condiciones pueden expresarse formalmente como restricciones sobre el grafo espacial del apartamento. Si $G = (V, E, X)$ representa el plano, donde cada nodo $v_i \in V$ es una estancia con tipo semántico t_i , área a_i y posición p_i , y cada arista $e_{ij} \in E$ indica adyacencia funcional entre las estancias v_i y v_j , los condicionantes modulares pueden escribirse como:

$$a_{\min}(t_i) \leq a_i \leq a_{\max}(t_i) \quad \forall v_i \in V \quad (1)$$

Donde $a_{\min}(t_i)$ es el área mínima permitida para una estancia del tipo semántico t_i , a_i es el área (normalmente en m²) de la estancia/nodo v_i , $a_{\max}(t_i)$ es el área máxima permitida para t_i , y v_i es un nodo del grafo espacial que representa una estancia, con V siendo el conjunto de nodos (estancias).

$$l_{\min}(t_i) \leq l_i \leq l_{\max}(t_i) \quad \forall v_i \in V \quad (2)$$

Donde $l_{\min}(t_i)$ es el valor mínimo permitido para el lado/dimensión mínima asociada al tipo t_i (por ejemplo, el menor lado utilizable), l_i es la dimensión/valor de lado de la estancia v_i , $l_{\max}(t_i)$ es el valor máximo permitido para el tipo t_i , v_i es un nodo que representa una estancia y V es el conjunto de nodos (estancias).

$$\exists e_{ij} \in E \text{ si } (t_i, t_j) \in \mathcal{A} \quad (3)$$

Donde e_{ij} es una arista (relación de adyacencia) entre las estancias/nodos v_i y v_j , E es el conjunto de aristas del grafo espacial, t_i y t_j son los tipos semánticos de las estancias en v_i y v_j , y \mathcal{A} es el conjunto de pares de tipos que deben cumplir una relación de adyacencia (condición de compatibilidad tipo-tipo), por ejemplo, baño adyacente a dormitorio o pasillo.

Esta representación formal permite verificar automáticamente el cumplimiento de los condicionantes sobre cualquier diseño generado.

El flujo de trabajo actual entre el promotor y el industrializador implica varios ciclos de iteración manual para ajustar un proyecto convencional al catálogo modular. El objetivo es que la IA generativa automatice la exploración de alternativas válidas, reduciendo el tiempo de cada ciclo de horas a segundos.

3 Estado del arte

3.1 Grafos en el dominio de la arquitectura y la construcción

El uso de grafos y grafos de conocimiento (*knowledge graphs*) en el dominio AECO ha experimentado un crecimiento notable en los últimos años [2]. Dos problemas recurrentes justifican este interés: la integración de datos heterogéneos (BIM, Internet of Things, sensores, normativa) en un marco semántico común y consultable, y el razonamiento espacial y topológico sobre edificios, para el que la representación en grafo es inherentemente más adecuada que los modelos geométricos puros.

En el ámbito del análisis de layouts residenciales, trabajos recientes han demostrado que los grafos espaciales (donde nodos y aristas codifican estancias y conexiones, enriquecidos con atributos morfológicos y de centralidad) permiten caracterizar tipológicamente el stock residencial existente mediante aprendizaje automático supervisado y apoyar procesos de gestión del patrimonio construido a escala urbana [2, 4]. Esta capacidad analítica sienta las bases para dar el salto hacia la generación.

3.2 Generación automática de planos de planta

La generación automática de planos de planta mediante IA ha avanzado de forma acelerada desde los primeros trabajos de aprendizaje profundo en la materia [5]. RPLAN [6] (SIGGRAPH Asia 2019) fue uno de los trabajos pioneros, proponiendo un sistema que genera distribución de planta condicionadas por el contorno del edificio y el grafo de adyacencia entre estancias, a partir de un corpus de decenas de miles de plantas reales. Este trabajo estableció el paradigma de la generación condicionada que domina la literatura posterior.

Las redes generativas adversariales (GANs) dieron continuidad a esta línea: House-GAN [3] y ActFloor-GAN demostraron la viabilidad del aprendizaje de distribuciones de planos a partir de datos, condicionando la generación por un grafo de adyacencia entre estancias. Sin embargo, estos modelos presentaban baja diversidad, dificultades para respetar el programa habitacional y limitaciones a distribuciones rectangulares.

Los modelos basados en difusión han supuesto un salto cualitativo. HouseDiffusion [7] (CVPR 2023) genera planos en formato vectorial mediante un proceso de eliminación iterativa de ruido sobre coordenadas de vértices, condicionado por un grafo de adyacencia (*bubble diagram*). Cons2Plan [8] propone un sistema de dos etapas que acepta como condición un grafo de adyacencia, un contorno de edificio, o ambos. El dataset Modified Swiss Dwellings (MSD) [9] (ECCV 2024), con más de 5.300

plantas completas y 15.900 apartamentos individuales anotados, ha consolidado un marco de referencia para la evaluación de modelos de mayor complejidad.

Sin embargo, la literatura evidencia una laguna conceptual relevante. La mayoría de los sistemas condicionan la generación exclusivamente por el contorno del edificio y, en algunos casos, por un grafo de adyacencia o el número de habitaciones. La incorporación sistemática de restricciones normativas (superficies mínimas, separaciones reglamentarias), criterios energéticos (orientación, compacidad), preferencias del promotor o parámetros dimensionales finos por tipo de estancia permanece como un problema abierto [5, 10]. No se ha publicado hasta la fecha ningún sistema de difusión sobre grafos condicionado por contorno para apartamentos a la escala del dataset MSD [9]. En el caso específico de la vivienda modular industrializada, a estas restricciones se suman las dimensionales y constructivas propias del catálogo de módulos, añadiendo una capa de condicionamiento no abordada por ningún sistema conocido.

4 Enfoque propuesto

4.1 Representación formal del problema

El problema de diseño modular se formaliza como la generación de un grafo espacial $G = (V, E, X)$ que satisfaga simultáneamente las restricciones del programa habitacional, las restricciones del sistema modular y las restricciones normativas aplicables.

Cada nodo $v_i \in V$ representa una estancia con un vector de atributos $x_i \in X$:

$$x_i = (t_i, a_i, p_i, l_i) \quad (4)$$

Donde x_i es el vector de atributos del nodo/estancia v_i , $t_i \in \mathcal{T}$ es el tipo semántico de la estancia v_i , a_i es el área de la estancia v_i , p_i es la posición del centroide de la estancia v_i , y l_i es el vector de dimensiones (medidas geométricas/parámetros dimensionales) asociado a v_i . Cada arista $e_{ij} \in E$ indica adyacencia funcional entre las estancias v_i y v_j , pudiendo corresponder a paso directo, puerta o acceso exterior.

La Tabla 1 recoge los rangos de referencia para los principales tipos de estancia, derivados de la normativa D80/2022 aplicada en los proyectos de JIT Housing y del catálogo EKONSTEAM.

Tabla 1. Restricciones de área y lado mínimo por tipo de estancia.

Tipo de estancia	Área mín. (m ²)	Área máx. (m ²)	Lado mín. (m)	Lado máx. (m)
Dormitorio principal	10,0	20,0	2,8	5,0
Dormitorio secundario	6,0	14,0	2,4	4,0
Salón	14,0	35,0	3,0	7,0
Cocina	6,0	15,0	2,0	5,0
Baño completo	3,5	8,0	1,5	3,0
Pasillo / corredor	3,0	12,0	1,0	2,5
Terraza / balcón	4,0	15,0	1,5	5,0

4.2 Dataset y pipeline de datos

El dataset Modified Swiss Dwellings (MSD) [9] es el punto de partida para el entrenamiento de los modelos generativos. MSD contiene más de 5.300 plantas completas de edificios residenciales desglosadas en más de 15.900 grafos individuales de apartamento, con anotaciones semánticas de las estancias (7-9 categorías), geometría poligonal de cada espacio, grafo de adyacencia con tipos de conexión (paso, puerta, acceso exterior) y la máscara de contorno del edificio a nivel de planta. El conjunto se divide en subconjuntos de entrenamiento, validación y test en proporción aproximada 80/10/10.

El pipeline convierte esta representación heterogénea en tensores de entrenamiento: grafos con atributos de nodo (tipo semántico, posición normalizada de centroide) y máscaras de contorno de edificio como condición de generación. La Figura 3 ilustra las tres capas de representación que componen este pipeline, mostrándose la planta del edificio con anotaciones semánticas (izquierda), el grafo de adyacencia con tipos de estancia como atributos de nodo (centro) y la máscara de contorno del edificio empleada como condición de generación (derecha) [9].

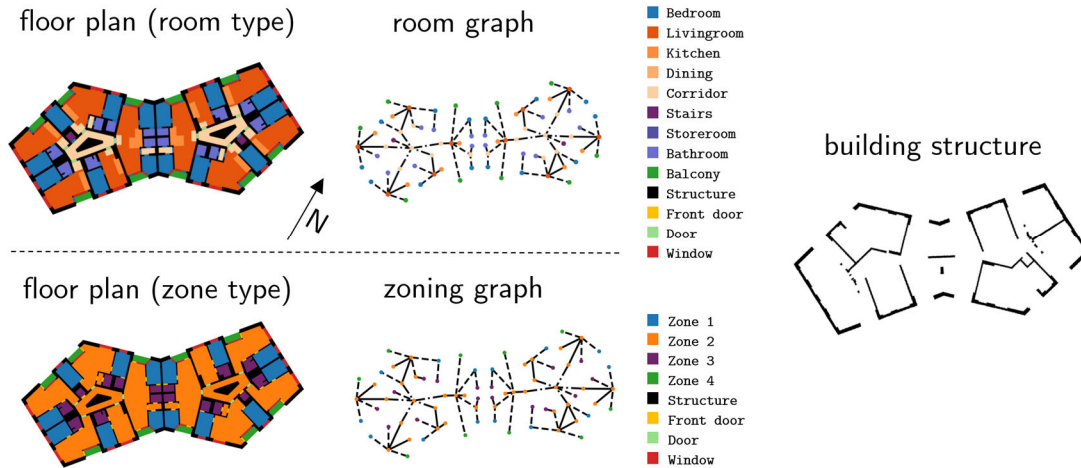


Figura 3. Pipeline de datos MSD

4.3 Marco de generación basado en difusión

Los modelos de difusión probabilística (DDPM o Denoising Diffusion Probabilistic Models, Ho et al. [11]) aprenden a generar muestras de una distribución de datos $p(x_0)$ a través de un proceso de eliminación iterativa de ruido. El proceso *forward* añade ruido gaussiano progresivamente en T pasos:

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t \mathbf{I}) \quad (5)$$

Donde $q(x_t | x_{t-1})$ es la distribución (conocida, del proceso *forward*) que describe cómo se genera x_t a partir de x_{t-1} , \mathcal{N} es una distribución normal (Gaussiana), x_t es la muestra/representación ruidosa en el paso de tiempo t , $\sqrt{1 - \beta_t}$ es el factor que escala x_{t-1} , x_{t-1} es la muestra/representación en el paso anterior, β_t es la magnitud de ruido introducida en el paso t , y \mathbf{I} es la matriz identidad (covarianza isotropa).

El proceso *reverse* (generación) aprende a invertir este proceso condicionado por las restricciones del usuario:

$$p_\theta(x_{t-1} | x_t, c) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t, c), \Sigma_\theta(x_t, t, c)) \quad (6)$$

Donde $p_\theta(x_{t-1} | x_t, c)$ es la distribución (aprendida, del proceso *reverse*) que estima x_{t-1} a partir de x_t condicionado por c , x_{t-1} es la representación del estado en el paso anterior (menos ruidoso), x_t es la representación del estado en el paso actual (mas ruidoso), c son las condiciones del usuario (por ejemplo programa habitacional y/o contorno del edificio), $\mathcal{N}(\cdot; \mu, \Sigma)$ es una distribución normal, el x_{t-1} de la media es el argumento de la Gaussiana, $\mu_\theta(x_t, t, c)$ es la media predicha por la red parametrizada por θ en función de x_t , el paso t y c , y $\Sigma_\theta(x_t, t, c)$ es la covarianza predicha por la red con la misma dependencia en x_t , t y c .

En el contexto de la generación de planos, x_0 representa el grafo espacial del apartamento (posiciones de las estancias y conectividad entre ellas), y el condicionamiento por c permite guiar la generación hacia soluciones que respeten el contorno del edificio y el programa deseado.

Este marco, aplicado por HouseDiffusion [7] sobre coordenadas vectoriales de planos, se ha adaptado en el presente trabajo al caso de mayor complejidad del dataset MSD, incorporando el condicionamiento por contorno.

4.4 Enfoques explorados: comparativa

El proceso de investigación ha recorrido sistemáticamente tres familias de métodos antes de converger en el enfoque basado en difusión.

El primer bloque de trabajo se centró en las heurísticas clásicas, con más de 13 prototipos incrementales que van desde la Partición Binaria del Espacio (BSP) hasta el Simulated Annealing (SA) con función de energía tipo Metropolis-Hastings. Este bloque ha permitido validar el flujo completo de datos y desarrollar una primera herramienta web funcional. Los layouts resultantes son correctos desde el punto de vista de las restricciones, pero presentan formas exclusivamente rectangulares y diversidad limitada.

Los modelos variacionales, basados en VGAE con capas de redes de grafos, han mostrado señales de aprendizaje sobre el dataset MSD pero con tendencia al sobreajuste en las escalas evaluadas, generando layouts sin respeto explícito al contorno del edificio.

Los modelos de difusión sobre grafos constituyen el enfoque principal en curso. El modelo desarrollado cuenta con aproximadamente 19 millones de parámetros en su componente de generación de posiciones y tipos de estancia, más un segundo componente de predicción de conectividad entre ellas. Los experimentos de validación técnica han confirmado la viabilidad del pipeline extremo a extremo sobre los datos MSD.

La comparación entre enfoques evidencia diferencias claras. Las heurísticas ofrecen bajo coste computacional y control explícito de restricciones, pero generan soluciones poco variadas y formalmente rígidas. Los modelos variacionales introducen mayor flexibilidad geométrica, aunque el sobreajuste limita tanto la diversidad como la calidad de los resultados. Los modelos de difusión, por el contrario, permiten incorporar el contorno del edificio como condición explícita y muestran un mayor potencial para producir distribuciones variadas y arquitectónicamente plausibles, a costa de un coste computacional considerablemente superior, especialmente durante la inferencia iterativa.

En conjunto, los resultados obtenidos apuntan a los modelos de difusión condicionados por contorno como la línea más prometedora para el diseño generativo de vivienda modular industrializada, al combinar flexibilidad geométrica, capacidad de condicionamiento y escalabilidad sobre datasets complejos como MSD.

4.5 Herramienta de exploración de diseños: Layout Lab

En paralelo al desarrollo de los modelos generativos, se ha desarrollado una herramienta web local (**Layout Lab**) que permite a técnicos de diseño explorar alternativas de distribución modular de manera interactiva. La herramienta integra actualmente el motor generativo heurístico y está diseñada para incorporar el modelo de difusión entrenado a escala en una fase posterior.

El flujo de trabajo de la herramienta comprende tres pasos. El técnico comienza configurando el problema: introduce las dimensiones del contorno rectangular (ancho y fondo, en metros), el programa de estancias (dormitorios, baños, salón, cocina, comedor, pasillos, trasteros, balcones), la orientación de la entrada y, opcionalmente, las restricciones por tipo de estancia (lados mínimo y máximo, área mínima y máxima). A continuación, el sistema genera hasta 6 alternativas de distribución aplicando las restricciones definidas y las estadísticas del dataset MSD como referencia. Por último, cada propuesta se visualiza en un canvas interactivo con indicadores de calidad y un módulo de búsqueda de layouts similares en el dataset de referencia. La Figura 4 muestra la interfaz completa de la herramienta con un caso de uso real, donde se aprecian el panel de configuración (izquierda) y el panel de resultados

(derecha) con el layout seleccionado, las cuatro alternativas generadas con sus scores de calidad, y los indicadores detallados de score global, afinidad MSD, adyacencia, luz perimetral, compacidad, circulación y cumplimiento de restricciones.

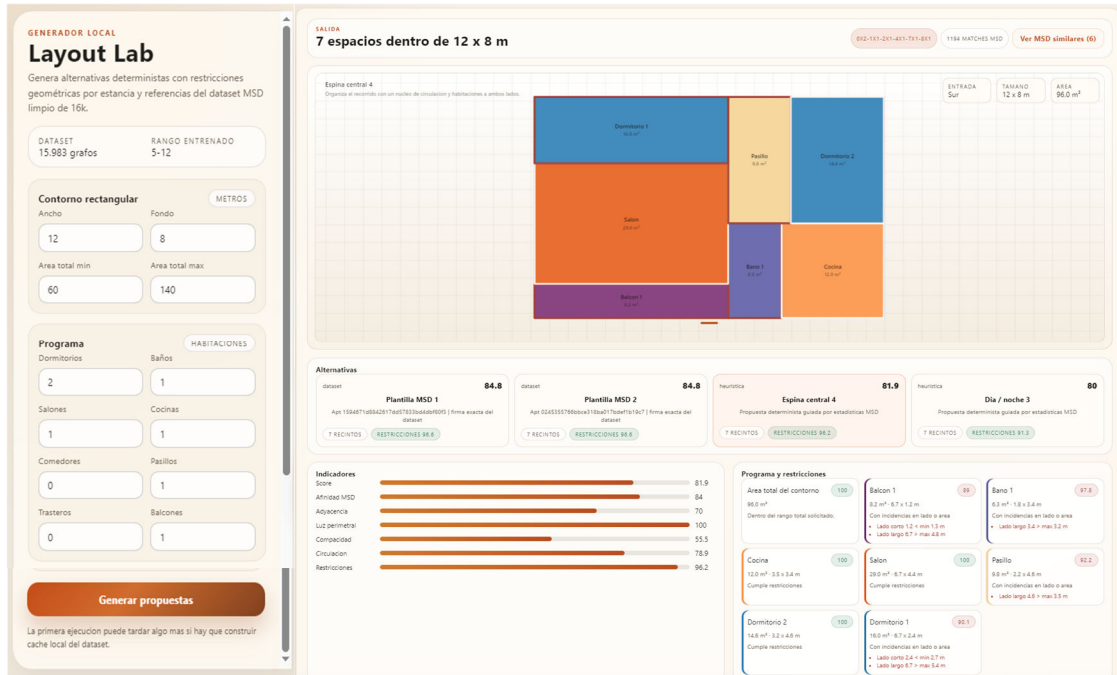


Figura 4. Interfaz de la herramienta Layout Lab.

5 Resultados e impacto

5.1 Demostrador funcional

La herramienta Layout Lab constituye uno de los entregables tangibles del proyecto: un demostrador funcional que valida el concepto de diseño asistido por IA para sistemas modulares.

Frente al proceso manual actual (en el que un técnico dedica varias horas a explorar alternativas de distribución compatibles con el módulo EKONSTEAM, verificando restricciones normativas y constructivas de forma individual), la herramienta genera múltiples alternativas en segundos y presenta automáticamente los indicadores de cumplimiento. El técnico puede explorar variantes modificando el programa o las restricciones en tiempo real, y revisar ejemplos similares del dataset MSD para contextualizar cada propuesta. La Figura 5 muestra el panel de detalle de la herramienta, que ilustra la diversidad de distribuciones que el sistema produce ante una misma configuración de entrada. El panel muestra el ranking (arriba) de las seis alternativas generadas por Layout Lab para el mismo programa de entrada, con indicación de su origen y sus scores de calidad. Además, muestra un subpanel de layouts similares del dataset MSD (abajo), que permiten al técnico contrastar las propuestas generadas con plantas reales del corpus de entrenamiento.

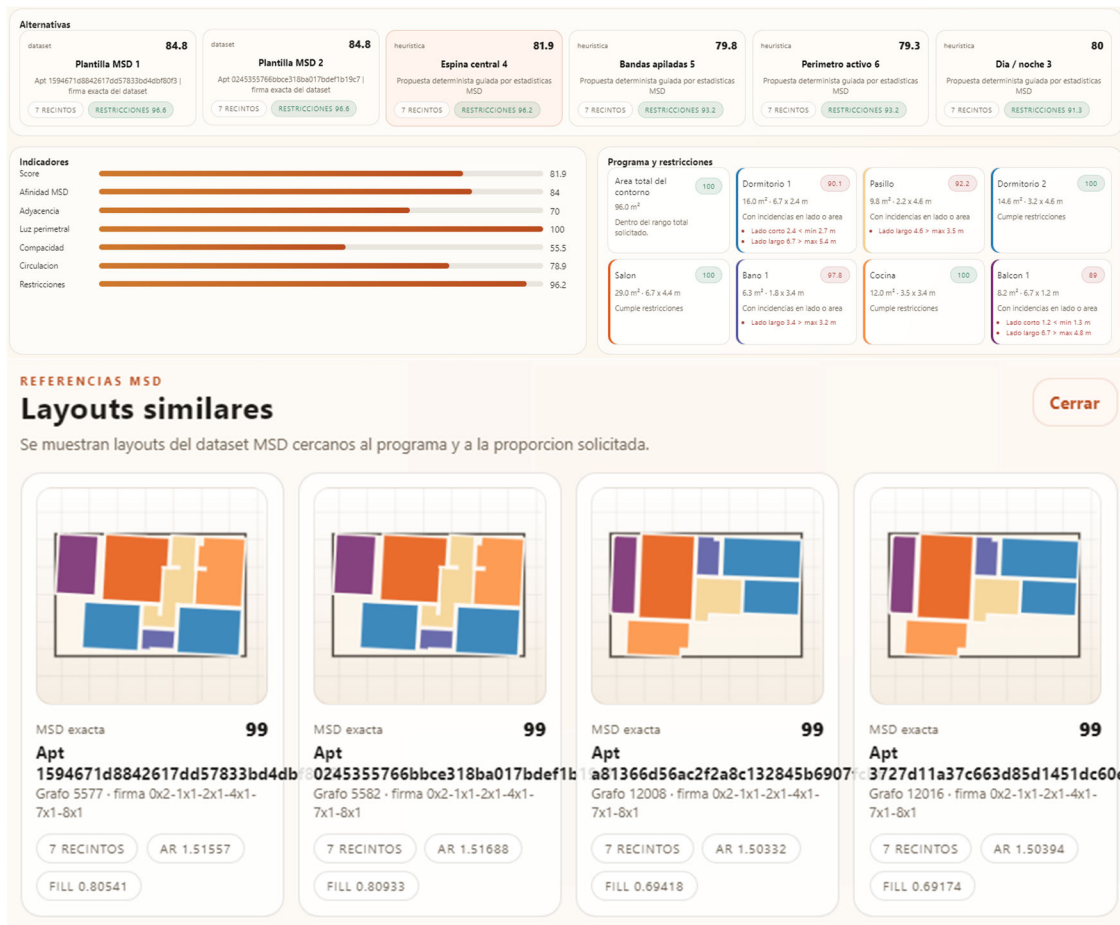


Figura 5. Panel de detalle

Este demostrador representa también la base tecnológica sobre la que se integrará el modelo de difusión entrenado a escala: la arquitectura modular del backend y la interfaz de usuario están preparadas para sustituir el motor heurístico actual por el modelo generativo sin cambios en la experiencia de usuario.

5.2 Estimación del impacto en productividad

La estimación del impacto se basa en el análisis del flujo de trabajo actual en proyectos reales de JIT Housing y VDS. La fase de diseño de distribución modular implica habitualmente dos a cuatro ciclos de iteración entre el proyectista (VDS) y el equipo de ingeniería de JIT, con reuniones de revisión y ajustes hasta alcanzar una solución que cumpla simultáneamente el programa, las restricciones del módulo y la normativa aplicable. Cada ciclo de iteración consume entre media jornada y una jornada completa de trabajo técnico.

Entre los objetivos de VDS en esta línea de investigación se encuentra la **reducción del 50% del tiempo de diseño detallado** mediante la automatización de la exploración de alternativas válidas.

La herramienta actual ya reduce significativamente el tiempo de exploración inicial al automatizar la generación de alternativas y la verificación de restricciones. Con la incorporación del modelo de difusión entrenado (prevista para el segundo semestre de 2026 en el clúster HPC (High Performance Computing) KATEA de Tecnalia), se espera alcanzar el objetivo de reducción del 50% en la fase de diseño exploratorio, liberando tiempo de ingeniería para las fases de valoración y ajuste fino.

5.3 Impacto en el flujo promotor-industrializador

El impacto estratégico de la herramienta reside en su capacidad de transformar el flujo de trabajo entre promotor (VDS) y fabricante (JIT Housing). Con una herramienta de diseño generativo basada en grafos, el proyectista puede explorar autónomamente un espacio amplio de soluciones compatibles con el catálogo de JIT antes de las reuniones de revisión, reduciendo el número de iteraciones y acortando el ciclo de desarrollo de cada proyecto.

A mediano plazo, la integración de la evaluación económica y ambiental en el mismo pipeline generativo (posible gracias a la vinculación con el catálogo verde y la taxonomía de circularidad desarrollados en el ámbito de TAMESIS por Semantic Systems) permitirá que cada propuesta generada venga acompañada de una estimación de coste de ciclo de vida y huella de carbono. Esto facilitará la toma de decisiones multicriterio en las primeras fases del proyecto, alineando diseño, industrialización y sostenibilidad desde el inicio.

6 Discusión y trabajo futuro

El trabajo presentado tiene dos limitaciones principales que conviene señalar explícitamente. En primer lugar, los modelos generativos basados en difusión están actualmente en fase de entrenamiento a escala: los experimentos realizados confirman la viabilidad técnica del pipeline, pero el entrenamiento completo sobre los datos de MSD está previsto para el segundo semestre de 2026. En segundo lugar, la validación con diseñadores reales de los outputs del modelo (incluyendo evaluación arquitectónica y de cumplimiento normativo) está pendiente de planificación en el marco del proyecto.

El trabajo futuro inmediato se estructura en tres líneas:

1. Entrenamiento a escala completa del modelo de difusión en el clúster HPC KATEA de Tecnalia.
2. Integración del modelo entrenado en la herramienta Layout Lab, sustituyendo el motor heurístico actual.
3. Validación con arquitectos y técnicos de VDS y JIT Housing sobre proyectos reales, midiendo la reducción efectiva del tiempo de diseño frente al proceso manual.

La visión a largo plazo, alineada con la reflexión de Massafra [2] sobre el futuro de los sistemas de conocimiento de edificios integrados con IA, apunta hacia una infraestructura donde la misma representación semántica en grafo que permite analizar y clasificar edificios existentes alimenta directamente los modelos generativos para nuevos diseños. Este continuo analítico-generativo (anclado en ontologías abiertas e interoperables como BOT Building Topology Ontology, Brick e IFC) podría convertirse en la base de las herramientas de diseño asistido de próxima generación para la construcción industrializada. La clave reside en que el conocimiento del dominio (restricciones constructivas, normativa, catálogos de módulos) quede codificado en el grafo de forma explícita y consultable, de modo que la IA genere dentro de un espacio de soluciones validado por el criterio experto.

7 Conclusiones

Este trabajo presenta tres contribuciones principales del proyecto TAMESIS de VDS en la línea de investigación de diseño generativo modular.

En primer lugar, la **formalización del problema de diseño modular como generación de grafos espaciales** sujetos a restricciones constructivas, normativas y de programa habitacional, estableciendo un vínculo explícito entre la representación de edificios como redes y el diseño generativo basado en IA.

En segundo lugar, la **exploración y comparación sistemática de tres familias de métodos** (heurísticas clásicas, modelos variacionales y modelos de difusión sobre grafos), identificando los

modelos de difusión condicionados por contorno como el enfoque más prometedor para el caso de uso específico de la vivienda modular industrializada en altura.

En tercer lugar, el **desarrollo de un demostrador web funcional** (Layout Lab) que hace tangible el flujo completo desde la definición del programa hasta la generación y comparación de alternativas de distribución modular, y que constituye la base tecnológica para la integración futura del modelo generativo entrenado.

El impacto esperado es una reducción de la mitad del tiempo de diseño detallado cuando los modelos generativos se integren completamente, contribuyendo a uno de los objetivos de VDS de mejorar la productividad del sector de la construcción industrializada en más de un 30% para 2029.

La convergencia entre grafos de conocimiento e IA generativa abre una vía de transformación para el diseño de vivienda industrializada: del diseño manual iterativo al diseño asistido por IA con validación automática de restricciones, manteniendo al proyectista en el centro del proceso creativo como curador y validador de las soluciones propuestas.

8 Agradecimientos

Este trabajo ha sido desarrollado en el marco del proyecto TAMESIS, financiado por el programa HAZITEK del Gobierno Vasco y cofinanciado por la Unión Europea mediante el Fondo Europeo de Desarrollo Regional (FEDER).

Referencias

- [1] VISESA (2021). *Libro Blanco de la Vivienda Social Industrializada*. Gobierno Vasco, Viceconsejería de Vivienda.
- [2] Massafra, A. (2026). *Buildings as Networks: Modelling Built Heritage Knowledge Through Graphs*. Fondazione Bologna University Press. DOI: 10.30682/9791254777954
- [3] Nauata, N., Chang, K.-H., Cheng, C.-Y., Mori, G., y Furukawa, Y. (2021). *House-GAN: Relational generative adversarial networks for interiors layout generation*. Computer Vision – ECCV 2020, Springer.
- [4] Massafra, A., Al-Harasis, D., Stefanini, L., y Jabi, W. (2025). *Semi-automated dataset generation for residential buildings using graph-based topological modelling*.
- [5] Saliu, O., y Elezi, I. (2025). *Integration of artificial intelligence in floorplan layout planning: a systematic review of models, methods, and applications (2020–2025)*. *European Chronicle*: <https://echronicle.com.ua/index.php/home/article/view/68>
- [6] Wu, W., Fu, X.-M., Tang, R., Wang, Y., Qi, Y.-H., y Liu, L. (2019). *Data-driven interior plan generation for residential buildings*. ACM Transactions on Graphics (SIGGRAPH Asia 2019), 38(6), Article 234.
- [7] Shabani, M. A., Hosseini, S., y Furukawa, Y. (2023). *HouseDiffusion: Vector floorplan generation via a diffusion model with discrete and continuous denoising*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2023), 5493–5502.
- [8] Hong, Q., Wang, W., Li, X., Chen, Z., Liu, L., y Meng, W. (2024). *Cons2Plan: Vector floorplan generation from various conditions via a learning framework based on conditional diffusion models*. Proceedings of ACM Multimedia 2024.
- [9] van Engelenburg, C., Loy Puddu, E., Venet, A., Nan, L., y Gool, L. van (2024). *MSD: A benchmark dataset for floor plan generation of building complexes*. European Conference on Computer Vision (ECCV 2024), Springer.
- [10] Zeng, Z., Li, T., Dong, J., y Pan, Z. (2024). *Residential floor plans: Multi-conditional automatic generation using diffusion models*. Frontiers of Computer Science, Springer.
- [11] Ho, J., Jain, A., y Abbeel, P. (2020). *Denosing diffusion probabilistic models*. Advances in Neural Information Processing Systems (NeurIPS 2020), 33, 6840–6851.