



## Conversión de patrones en isométricas a través de redes generativas antagónicas (GANs)

Diego Navarro-Mateu (1); Oriol Carrasco (2); Pedro Cortés Nieves (1)

(1) *Expresión gráfica, Universitat Internacional de Catalunya;* (2) *Advanced Architecture group, Institute for advanced architecture of Catalonia*



Figura 1. Catálogo de diez isométricas que muestran la progresión de la red neuronal (NN1) durante su entrenamiento (Autores, 2021)

### Resumen

*El ejercicio de la arquitectura se sustenta en un proyectar compuesto de diferentes niveles de abstracción. Desde la conceptualización de los espacios hasta la expresión de la geometría, existe una información jerárquica susceptible de ser abstraída a modo de patrón. La presente investigación plantea la posibilidad de comprimir y codificar dicha información en cuadrículas de colores que puedan ser interpretados por una inteligencia artificial (red generativa adversa (cGAN)) para que esta pueda representar un objeto arquitectónico.*

*El desarrollo del aprendizaje automático ('machine learning', ML) nos permiten introducir nuevos flujos de trabajos tanto para el diseño como para el análisis. Mediante la asociación de imágenes, esta investigación genera isométricas que representen arquitecturas relativamente complejas a partir de un código cromático simplificado. En dicha investigación, el entrenamiento de dos redes neuronales pone a prueba la posibilidad de aplicar una codificación indirecta, así como su respuesta y flexibilidad a elementos externos fuera de las bases de datos iniciales.*

### Palabras clave

*Inteligencia artificial; diseño generativo; diseño paramétrico; patrones; aprendizaje automático;*

## 1. Introducción y antecedentes

Esta comunicación plantea una serie de ámbitos y conceptos computacionales que establecen los requisitos necesarios para plantear la hipótesis de que puede existir una codificación gráfica con elevado potencial para la arquitectura. Dicha hipótesis, ya ha sido corroborada y publicada con anterioridad (Navarro-Mateu, Carrasco and Cortes Nieves, 2021).

Tras exponer el marco teórico, el capítulo dos describe pruebas realizadas con el fin de seguir profundizando en este tipo de codificación, especialmente en lo que se refiere a su flexibilidad frente a casos externos.

### 1.1. La Inteligencia Artificial y su influencia.

El aprendizaje automatizado (ML) ha disfrutado de un despertar tardío en los últimos años gracias a un hardware y software mucho más accesible, que ha posibilitado su uso en distintas disciplinas: representación, aprendizaje, razonamiento, planeamiento, o reconocimiento entre otras.

Sin duda, una de las habilidades más sorprendente de estos algoritmos es la capacidad de realizar tareas específicas sin la necesidad de describir las instrucciones (Back, Hammel and Schwefel, 1997).

Los diferentes tipos de aprendizajes automatizados entre los que se incluyen las redes neuronales han logrado revolucionar los campos de visión por ordenador, reconocimiento de audio y voz, traducción automática, filtrado de redes sociales, bioinformática, diseño de fármacos y mucho más. Por tanto, nos encontramos con un motor de cambio a corto plazo con implicaciones sociopolíticas y económicas.

Algunos de estos algoritmos reconocen o generan imágenes si disponen de bases de datos para el entrenamiento de los mismos. A mayor tamaño y calidad de dichas bases, mayor efectividad del algoritmo.

### 1.2. Redes Generativas Adversas Condicionales (cGANs)

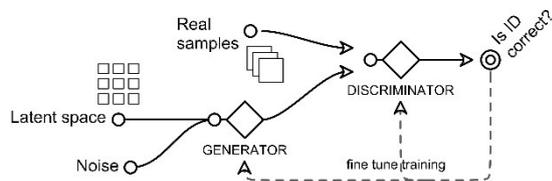


Figura 2. Esquema de una Red Generativa Adversa Condicional (Autores, 2020).

Los algoritmos cGAN se fundamentan en una función que ha sido previamente entrenada. Particularmente, sets de imágenes estructuradas en parejas. El entrenamiento permite discernir los resultados apropiados mediante un proceso en el que participa un Discriminador que los evalúa. Un Generador, produce nuevos datos -imágenes- que el Discriminador reconoce como adecuados (Radford, Metz and Chintala, 2016).

En el marco de este artículo, el cGAN es usado como una solución para la conversión imagen-a-imagen mediante el reconocimiento de píxeles y el modelo pix2pix. (Zhu *et*

*al.*, 2017; Wang *et al.*, 2018).

### 1.3. Arquitectura y aprendizaje automático.

La influencia de la computación en la arquitectura en las últimas décadas es innegable. No solo como herramienta de producción, sino como discurso conceptual en la ideación de proyectos.

Especial pero no exclusivamente, John Frazer alude a la arquitectura manifestada como resultado de complejas reglas generativas, que pueden ser expresadas como un lenguaje pseudo-genético producido por una sucesión de instrucciones (Frazer, 1995). Posteriormente, esta evolución incide sobre los procesos de morfogénesis asociados a criterios de adaptabilidad aplicados en la arquitectura (Hensel, Menges and Weinstock, 2013).

Cuando profundizamos en el uso de ML y arquitectura, es de obligada mención el trabajo de Stanislas Chaillou (Chaillou, 2019) en la generación y diseño de plantas y la incorporación de diferentes tipologías y estilos. Así como la zonificación de Huang & Zheng (Huang and Zheng, 2018) o las fachadas de Mohammad *et al.* (Mohammad, 2019).

Actualmente, aunque ya existen casos de aplicación en representación 3D o 2.5D, la mayoría de los ejemplos relacionados con la arquitectura se reducen a una conversión directa y 2D.

### 1.4. Patrones, datos y generación

Las GANs, han sido particularmente exitosas en la generación de imágenes (píxeles), y son capaces de extrapolar formas y posibles relaciones entre ellas (Isola *et al.*, 2017). Sin embargo, aunque añaden complejidad y “comprenden” el contenido de las mismas, la relación espacial entre los píxeles y su información no es cambiante.

Frente a las conversiones directas -y relativamente predecibles, en las que la estructura de los píxeles entre imagen referencia y generada permanece constante- los autores proponen el uso de una conversión indirecta para la generación de arquitectura.

Una conversión indirecta es fundamental para construir un sistema complejo, porque introduce la posibilidad de jerarquizar la información. Igualmente fundamental es la capacidad para codificar la información que nutre la complejidad de la arquitectura.

A través de un set muy limitado de reglas, los patrones de información establecen relación entre los datos, poseen propiedades fractales y son susceptibles de ser escalados o adaptados (West, Brown and Enquist, 1999).

¿Qué capacidad tiene una cGAN para realizar conversiones indirectas? ¿Cuán abstracta puede ser dicha conversión? ¿Qué flexibilidad demostrará fuera de los casos del entrenamiento?

## 2. Discusión (metodología y resultados)

La importancia reciente del ‘big data’ viene dada por la dificultad de recopilar y catalogar las bases de datos. No obstante, gracias al diseño paramétrico, el planteamiento

cuenta con una gran ventaja: la base de datos para alimentar la red neuronal es producida por los mismos usuarios.

Por lo cual, se han generado patrones referencia e isométricas objetivo (figura 3) mediante una definición algorítmica (Grasshopper, plug-in para Rhinoceros3D)

Los experimentos se han computado en Google Colab, en el entorno Python 3.6 (v3.6.x, 2019, USA) y en configuración local (CPU: Core i7-7700HQ de Intel (MSI Apache); GPU: GeForce GTX 1050 Ti de 4 GB; RAM: 16 GB (DDR4); HD: 256 GB SSD).

### 2.1. Sistema de patrones y colores.

A partir de investigaciones anteriores (Navarro-Mateu and Cocho-Bermejo, 2020), se ha establecido un modelo generativo de malla poligonal que responde a una rejilla de diferentes colores.

En la primera fase de esta investigación (Navarro-Mateu, Carrasco and Cortes Nieves, 2021) puede consultarse una descripción detallada del código de colores y como afectan a los diferentes aspectos compositivos de la arquitectura como volúmenes, subdivisión y aperturas.

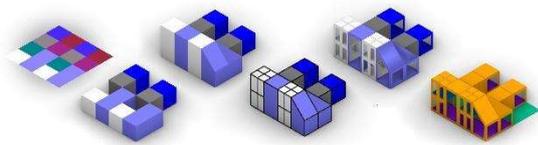


Figura 3. De izquierda a derecha, la sucesiva evolución del patrón de colores en una isométrica arquitectónica mediante modelado paramétrico (Autores 2020).

De esta primera publicación se concluyó el impacto positivo del uso de colores; un balance apropiado entre la cantidad de reiteraciones (epochs) y el tamaño de la base de datos; y la respuesta de transformación a los patrones. También se concluyó que el punto débil de esta estrategia es su adaptación a tipologías fuera del entrenamiento. Es decir, una baja capacidad de extrapolación.

Para testear este aspecto, este caso entrena dos redes neuronales con una base de datos de 500 imágenes (128px de lado) y 100 ciclos ('epochs') cada una. La primera red (NN1) solo contiene patrones de 4x4 celdas, mientras que la segunda (NN2) dispone a partes iguales rejillas de 3x3, 4x4 y 5x5. Por tanto, la NN2 debería presuponerse más flexible pero de menor calidad debido a la dispersión de tres tamaños distintos.

Por último, ambas redes se someten a la conversión de patrones exentos en su base de datos: la NN1 a un patrón 5x5, y la NN2 a uno de 6x6 (remapeado a 128bits).

El análisis de los resultados consiste en comparar la semejanza de las imágenes generadas con sus supuestos teóricos usando los diferentes tamaños de patrones en las dos redes (tabla 1).

### 2.2. Resultados

En función del porcentaje en el análisis de semejanza en la tabla 1 se corrobora que:

- El Test A es 1,07% mejor que el test B. Una diferencia

mínima teniendo en cuenta que la base de datos es tres veces menor.

- El test B y D presentan gran similitud, como cabría esperar debido a sus puntos de partida.
- El test E respecto al test C presenta una mejoría del 2.89% a pesar del remapeo de las imágenes.

Tabla 1: valores de semejanza de los patrones en las redes neuronales.

Comentario de imagen input	Test (patrón y Red Neuronal)	Valor de semejanza (%)
Entrenada (100%)	A (4x4 NN1)	97,98
Entrenada (33%)	B (4x4 NN2)	96,91
Externa	C (5x5 NN1)	77,62
Entrenada (33%)	D (5x5 NN2)	96,01
Externa - remapeada	E (6x6 NN2)	80,51

### 3. Conclusiones

A pesar de contar con unos medios tecnológicos modestos, la cGAN de nuevo demuestra ser capaz de reproducir objetos arquitectónicos a partir de un patrón de colores sencillo. Las arquitecturas generadas (figura 4) establecen relaciones extrínsecas a partir de las celdas vecinas, lo que sugiere una extrapolación viable -aunque precavida- a la escala urbana (Rittel and Webber, 1973).



Figura 4. Resultados de la NN2 en las diferentes rejillas. De izquierda a derecha: patrón, isométrica teórica y resultado predicho por la NN (Autores, 2021).

En términos generales, los resultados de esta segunda fase muestran que introducir más variedad presenta una reducción mínima de calidad que compensa en flexibilidad frente a casos no entrenados (figura 5).

Por otro lado, la estructura de la imagen parece ser más relevante que el escalado o el tamaño de los elementos en la misma (test C vs E).

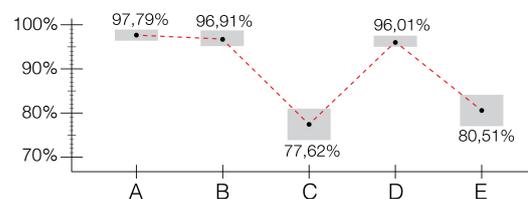


Figura 5. Gráfico de líneas con los resultados de los test A-E (Autores, 2021).

Más allá del potencial disruptivo respecto al modelado y representación 3D, las implicaciones de esta metodología son numerosas: desde la compresión jerárquica de una arquitectura realista, hasta la especulación en los límites de la complejidad abarcable. Un planteamiento exhaustivo de estas metodologías abre nuevas puertas a la representación gráfica de la arquitectura, especialmente interesante desde los lenguajes que permitan su codificación.

#### 4. Referencias

Back, T., Hammel, U. and Schwefel, H. P. (1997) 'Evolutionary computation: Comments on the history and current state', *IEEE Transactions on Evolutionary Computation*, pp. 3–17. doi: 10.1109/4235.585888.

Chaillou, S. (2019) 'AI+ Architecture: Towards a New Approach', Harvard University.

Frazer, J. (1995) *An Evolutionary Architecture*, An Evolutionary architecture. University of Minnesota: Architectural Association. Available at: <http://www.aaschool.ac.uk/publications/ea/intro.html>.

Hensel, M., Menges, A. and Weinstock, M. (2013) *Emergent technologies and design: towards a biological paradigm for architecture*. Abington Thames, UK: Routledge.

Huang, W. and Zheng, H. (2018) 'Architectural drawings recognition and generation through machine learning'. CUMINCAD.

Isola, P. et al. (2017) 'Image-to-image translation with conditional adversarial networks', in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*. doi: 10.1109/CVPR.2017.632.

Mohammad, A. S. A. Q. (2019) 'Hybrid Elevations Using GAN Networks'. The University of North Carolina at Charlotte.

Navarro-Mateu, D., Carrasco, O. and Cortes Nieves, P. (2021) 'Color-Patterns to Architecture Conversion through Conditional Generative Adversarial Networks', *Biomimetics*. doi: 10.3390/biomimetics6010016.

Navarro-Mateu, D. and Cocho-Bermejo, A. (2020) 'Evo-devo strategies for generative architecture: Colour-based patterns in polygon meshes', *Biomimetics*, 5(2). doi: 10.3390/BIOMIMETICS5020023.

Radford, A., Metz, L. and Chintala, S. (2016) 'Unsupervised representation learning with deep convolutional generative adversarial networks', in *4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings*.

Rittel, H. W. J. and Webber, M. M. (1973) 'Dilemmas in a general theory of planning', *Policy Sciences*, 4(2), pp. 155–169. doi: 10.1007/BF01405730.

Wang, T. C. et al. (2018) 'High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs', in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. doi: 10.1109/CVPR.2018.00917.

West, G. B., Brown, J. H. and Enquist, B. J. (1999) 'The fourth dimension of life: fractal geometry and allometric scaling of organisms', *science*. American Association for the Advancement of Science, 284(5420), pp. 1677–1679.

Zhu, J. Y. et al. (2017) 'Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks', in *Proceedings of the IEEE International Conference on Computer Vision*. doi: 10.1109/ICCV.2017.244.

#### Datos biográficos de los autores

Diego Navarro-Mateu  
Universitat Internacional de Catalunya.  
navarro@uic.es

Dr. Diego Navarro es Arquitecto y máster en Arquitectura Biodigital por la Universitat Internacional de Catalunya - School of Architecture, donde ejerce como profesor Adjunto en grado y posgrado en los ámbitos de computación y grafismo desde 2009. Su doctorado recibió la beca "Junior Faculty" de fundación L'Obra Social "La Caixa". Desarrolla su investigación en diseño paramétrico-procedural y la implementación de algoritmos EVO-DEVO aplicados a Arquitectura.

A nivel empresarial ha colaborado en varias empresas para la parametrización de espacios y la mejora de software BIM, además de infografista en numerosos proyectos para el Ayuntamiento de Barcelona y otros despachos.

Oriol Carrasco  
Institute for advanced architecture of catalonia.  
Oriol.carrasco@iaac.net

Doctor Arquitecto por la EsARQ-UIC, escuela en la que es profesor asociado en Diseño Computacional y forma parte del grupo de investigación LITEIS. Es profesor en IED Barcelona, donde coordina el departamento de Computación en Diseño. Ejerce también de docente en IAAC, co-dirigiendo la línea de investigación 'Design With Nature'.

Durante los últimos 15 años ha estado combinando su carrera académica con el sector de la ingeniería y edificación, colaborando con varios estudios y compañías para la realización de obras complejas en Europa y Sud-América. Su experiencia profesional se centra alrededor del diseño computacional y los sistemas de fabricación contemporáneos.

Pedro Cortés Nieves  
Universitat Internacional de Catalunya.  
pcortes@uic.es

Pedro Cortés es diseñador computacional y desarrollador de software. Con una experiencia de más de siete años en el campo de la AEC y el desarrollo de herramientas digitales. Como parte del departamento de innovación, diseña soluciones algorítmicas que en última instancia pueden ser utilizadas para la fabricación digital.

También tiene experiencia docente en Studio Banana, la Universidad Politécnica de Madrid y Barcelona UIC, donde ha compartido su experiencia en computación y fabricación.

Se graduó con matrícula de honor en el Máster de Arquitectura Computacional (MIAU) de la Facultad de Arquitectura de la Universidad Politécnica de Madrid en 2018, y es arquitecto colegiado por la Universidad de Valladolid. También se ha formado como ingeniero de software (.NET full stack) en Barcelona Activa (2020).