



MÁSTER UNIVERSITARIO EN INGENIERÍA INDUSTRIAL

TRABAJO FIN DE MÁSTER

Generación de Redes Eléctricas de Distribución Sintéticas Mediante Inteligencia Artificial

Autor: Juan Manuel García-Pérez Merino


Director: Carlos Mateo Domingo

Madrid

10 de Julio de 2025

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
Generación de Redes Eléctricas de Distribución Sintéticas Mediante Inteligencia Artificial
en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el
curso académico 2024/25 es de mi autoría, original e inédito y
no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido
tomada de otros documentos está debidamente referenciada.



Fdo.: Juan Manuel García-Pérez Merino

Fecha: 11 / 07 / 2025

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO



Fdo.: Carlos Mateo Domingo

Fecha: 11/ 07/ 2025

GENERACIÓN DE REDES ELÉCTRICAS DE DISTRIBUCIÓN SINTÉTICAS MEDIANTE INTELIGENCIA ARTIFICIAL

Autor: García-Pérez Merino, Juan Manuel

Director: Mateo Domingo, Carlos

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

Este trabajo explora el uso de redes generativas antagónicas (GANs) para generar redes eléctricas de distribución sintéticas. Se desarrollan dos enfoques, uno que emplea ruido aleatorio como entrada y otro que utiliza imágenes como entrada para que el modelo genere imágenes en base a estos datos. El primer enfoque es útil para generar redes sintéticas generalistas, y el segundo enfoque va un paso más allá y permite proponer diseños para una red de distribución en una zona dada. Los resultados muestran que ambos modelos generan redes realistas, destacando especialmente la utilidad del modelo con imágenes de entrada ya que ofrece una mayor relación con el mundo real.

Palabras clave: Redes eléctricas sintéticas, Redes GAN, IA, Inteligencia Artificial, Redes generativas antagónicas

1. Introducción

La evolución de la red eléctrica hacia un modelo más digital y descentralizado ha aumentado la necesidad de contar con nuevas herramientas para operar estas redes [2][3]. Sin embargo, para poder entrenar correctamente estas herramientas es necesario contar con muchos datos cuyo acceso es muy restringido debido a problemas de confidencialidad, lo que dificulta la implementación de estas herramientas. Este proyecto investiga el uso de las redes GANs para generar redes eléctricas de distribución sintéticas que imiten la topología y características de las redes reales.

2. Definición del proyecto

Este TFM busca desarrollar un sistema basado en las redes GANs para generar redes eléctricas de distribución sintéticas. El proyecto se divide en dos modelos similares, donde uno toma ruido aleatorio como entrada y otra toma imágenes reales de nodos de demanda, callejero, o redes de menor tensión para generar una topología en base a esta entrada. El objetivo es conseguir un modelo capaz de generar representaciones realistas de redes de baja, media y alta tensión, que puedan ser utilizadas para validación y entrenamiento de herramientas de control y planificación, especialmente en contextos donde no se tienen datos reales.

3. Descripción del modelo

El modelo desarrollado se basa en la arquitectura de las redes GANs, teniendo dos componentes principales: un generador, encargado de generar imágenes de redes eléctricas en base a un ruido aleatorio o unos datos de entrada, y un discriminador, que evalúa las imágenes reales y las del generador y elige la que piensa que es real. En función del acierto o no del discriminador se refuerza más uno de los dos modelos.

El entrenamiento se realizó con imágenes sintéticas generadas, disponible en el dominio público, que son el resultado de una colaboración entre NREL, IIT-Comillas y MIT [1]. Se emplearon técnicas de preprocesamiento para tomar las imágenes de los archivos de QGIS, eliminar las que no aportaban información valiosa, y adaptarlas al formato y tamaño requeridos para cada entrenamiento. Además, se fueron ajustando los hiperparámetros como las tasas de aprendizaje, funciones de activación y tamaños de batch.




Ilustración 1 Esquema de una red GAN

4. Resultados

Se evaluaron los modelos desarrollados en siete escenarios distintos, variando el tipo de entrada (con y sin imágenes), el nivel de tensión representado (baja, media y alta), y el formato de entrada (color y blanco y negro). Los resultados muestran que los modelos que utilizan imágenes de entrada producen redes con mayor calidad, teniendo una distribución de elementos y líneas de tensión más realista.

Los casos en blanco y negro facilitaron el entrenamiento y generaban estructuras más claras sin necesidad de optimizar tanto los hiperparámetros, mientras que los casos con imágenes a color ofrecían más detalles, pero requerían un entrenamiento más ajustado y mayores recursos computacionales.

En algunos casos donde los entrenamientos no tenían la suficiente diversidad de entrada, o no estaba bien ajustado el número de épocas se dieron problemas como ruido de fondo y sobreajuste. Pero por lo general las redes GANs mostraron buenos resultados y una gran

capacidad de generar este tipo de redes. En la Ilustración 2 se muestran algunos ejemplos de redes generadas con esta metodología.




Ilustración 2 Resultados de generación de redes sintéticas en dos casos de estudio diferentes

5. Conclusiones

Este trabajo ha demostrado que las redes GANs son una herramienta viable para generar redes de distribución sintéticas. Ambos modelos han demostrado ser capaces de aprender los patrones estructurales de redes de distribución de diferentes niveles de tensión. El modelo con imágenes de entrada mostró una mayor estabilidad en el entrenamiento y un mayor realismo, mientras que cuando tenía ruido de entrada tenía una mayor variedad estructural.

A pesar de las limitaciones computacionales, que limitaron el tamaño de las imágenes y la duración del entrenamiento, los resultados obtenidos muestran que con más recursos se podrán obtener redes sintéticas a gran escala que podrán ser utilizadas en estudios y entrenamientos de herramientas. Sienta además las bases para el desarrollo de modelos más preciso y complejos que puedan integrar características de las redes como impedancias, pérdidas o flujos de potencia, permitiendo así su uso en aplicaciones más complejas.

6. Referencias

- [1] Mateo, C., Postigo, F., Elgindy, T., Birchfield, A. B., Dueñas, P., Palmintier, B., Panossian, N., Gómez, T., de Cuadra, F., Overbye, T. J., Safdarian, F., & Wallison, D. (2024). Building and validating a large-scale combined transmission & distribution synthetic electricity system of Texas. *International Journal of Electrical Power and Energy Systems*, 159, 110037. <https://doi.org/10.1016/j.ijepes.2024.110037>
- [2] Chaves, J. P., Cossent, R., Gómez, T., López, G., Matanza, J., Mateo, C., Rodríguez, N., & Sánchez, M. A. (2021). La digitalización de las redes eléctricas de distribución en España: Una visión desde la ingeniería. Fundación Ingenieros ICAI para el Desarrollo.
- [3] Postigo Marcos, F.E.; Mateo Domingo, C.; Gómez San Román, T.; Palmintier, B.; Hodge, B.-M.; Krishnan, V.; De Cuadra García, F.; Mather, B. A Review of Power Distribution Test

Feeders in the United States and the Need for Synthetic Representative Networks. *Energies*
2017

GENERATION OF SYNTHETIC ELECTRICAL DISTRIBUTION NETWORKS USING ARTIFICIAL INTELLIGENCE

Author: García-Pérez Merino, Juan Manuel.

Supervisor: Mateo Domingo, Carlos.

Collaborating Entity: ICAI – Universidad Pontificia Comillas

ABSTRACT

This work explores the use of Generative Adversarial Networks (GANs) for generating synthetic electric distribution networks. Two approaches are developed, one with random noise as input, and another using images as input, allowing the model to generate outputs based on this structured data. The first approach is useful for general-purpose synthetic networks, whereas the second approach goes a step further, enabling the generation of proposed designs for distribution networks adjusted to specific geographical areas. This work's results show that both models produce realistic network structures, especially in the case of the image-based model due to its higher correlation with real-world conditions.

Keywords: Synthetic electrical networks, GAN, AI, distribution, Artificial Intelligence, Generative Adversarial Networks

1. Introduction

The evolution of power grids toward a more digital and decentralized model has increased the need for new control and simulation tools to operate these networks [2][3]. However, to accurately train these tools large amounts of data are needed, which is often restricted due to confidentiality problems, limiting the training for these tools. This project analyzes the use of GANs to generate synthetic electric distribution networks that mimic the topology and characteristics of real-world power grids.

2. Project definition

This thesis develops an approach of making synthetic electrical distribution networks using a Generative Adversarial Networks (GANs) based system. The project consists of implementing two similar models, one based on random noise and the other using actual images of load nodes, road network, or low-tension networks mimic network layouts. The goal is to create a model that can generate different topologies of electrical distribution networks of low, medium, and high voltage, that can be used for validation and training of control and planning tools, especially in contexts where real-world data is unavailable.

3. Model Description

The developed model is based on GANs, which usually consist of two components: a generator, responsible for creating images of electric distribution networks, with its input being either random noise or structured data, and a discriminator, whose purpose is to evaluate real images and those created by the generator, determining which is more realistic. Based on the discriminator's success or failure, either the generator or discriminator is reinforced during the training process.

Training was carried out using publicly available synthetic images generated through a collaborative project between NREL, IIT-Comillas, and MIT [1]. Preprocessing consisted in extracting images from QGIS files, removing images that didn't contain enough information and adapting them to the required format and size needed for each study case. Furthermore, hyperparameters such as learning rates, activation functions, and batch sizes were progressively fine-tuned throughout the project.




Ilustración 3 GAN network diagram

4. Results

The developed models were evaluated across seven different case studies, each changing the type of input (with and without images), the voltage levels represented (low, medium, and high), and the input image format (color versus black-and-white). Results show that the models with input images produce networks of higher quality, with a more realistic distribution of network elements and power lines.

Cases using black-and-white images made the training process simpler, generating clear structures without a lot of optimizations, while color-image cases provided greater detail but required more adjustments and greater computational resources.

In some instances, insufficient input diversity or not the right number of epochs resulted in issues such as background noise and overfitting. Nonetheless, GAN models generally produced robust results, demonstrating significant capability generating synthetic power distribution networks. Examples of generated networks from two distinct case studies are shown in Figure 2.




Ilustración 4 Results generated in two different case studies

5. Conclusions

This work has shown that GANs are a viable tool for generating synthetic distribution networks. Both models have proven capable of learning the structural patterns of distribution networks at different voltage levels. The model with input images showed greater stability and realism during training, while the model with input noise showed greater structural variety.

Despite computational limitations, which limit the size of the images and the duration of training, the results obtained show that with more resources, large-scale synthetic networks can be obtained which can be used in studies and tool training. It also lays the foundation for the development of more accurate and complex models that can integrate network characteristics such as impedances, losses, or power flows, thus enabling their use in more complex applications.

6. References

- [1] Mateo, C., Postigo, F., Elgindy, T., Birchfield, A. B., Dueñas, P., Palmintier, B., Panossian, N., Gómez, T., de Cuadra, F., Overbye, T. J., Safdarian, F., & Wallison, D. (2024). *Building and validating a large-scale combined transmission & distribution synthetic electricity system of Texas*. *International Journal of Electrical Power and Energy Systems*, 159, 110037. <https://doi.org/10.1016/j.ijepes.2024.110037>
- [2] Chaves, J. P., Cossent, R., Gómez, T., López, G., Matanza, J., Mateo, C., Rodríguez, N., & Sánchez, M. A. (2021). La digitalización de las redes eléctricas de distribución en España: Una visión desde la ingeniería. Fundación Ingenieros ICAI para el Desarrollo.
- [3] Postigo Marcos, F.E.; Mateo Domingo, C.; Gómez San Román, T.; Palmintier, B.; Hodge, B.-M.; Krishnan, V.; De Cuadra García, F.; Mather, B. A Review of Power Distribution Test Feeders in the United States and the Need for Synthetic Representative Networks. *Energies* 2017

Índice de la memoria

Capítulo 1. Introducción	6
1.1 Introducción.....	6
1.2 Estructura del documento	7
Capítulo 2. Estado de la Cuestión	9
2.1 Generación de Redes de Distribución Sintéticas: Métodos y Estado Actual	9
2.1.1 Contexto y necesidad de redes sintéticas	9
2.1.2 Técnicas para generación de redes sintéticas	11
2.2 Descripción de las Tecnologías	15
2.3 Huecos en la investigación	20
2.4 Motivación	20
2.5 Alineación con los Objetivos de Desarrollo Sostenible (ODS).....	22
2.6 Objetivos	23
Capítulo 3. Definición del Trabajo	24
3.1 Metodología.....	24
3.1.1 Revisión del estado del arte y familiarización con modelos GAN.....	24
3.1.2 Preprocesamiento de datos	25
3.1.3 Diseño del modelo	26
3.1.4 Entrenamiento	28
3.1.5 Evaluación.....	29
Capítulo 4. Modelo Desarrollado.....	31
Capítulo 5. Análisis de Resultados.....	35
5.1 Resultados	35
5.1.1 Caso 1: Red de Distribución en Blanco y Negro (sin imágenes de entrada)	36
5.1.2 Caso 2: Red de Distribución con transformadores a color (sin imágenes de entrada) .	39
5.1.3 Caso 3: Red de Tensión en Blanco y Negro (con imágenes de entrada).....	43
5.1.4 Caso 4: Red de Baja Tensión (sin imágenes de entrada)	46
5.1.5 Caso 5: Red de Media y Alta Tensión (sin imágenes de entrada).....	50
5.1.6 Caso 6: Red de Baja Tensión (con imágenes de entrada).....	52

5.1.7 Caso 7: Red de Media y Alta Tensión (con imágenes de entrada).....	55
5.2 Discusión.....	58
Capítulo 6. Conclusiones y Trabajos Futuros.....	60
6.1 Conclusiones	60
6.2 Trabajos Futuros.....	62
Capítulo 7. Bibliografía.....	65

Índice de figuras

Ilustración 1 Esquema de una red GAN	5
Ilustración 2 Resultados de generación de redes sintéticas en dos casos de estudio diferentes	6
Ilustración 3 GAN network diagram	9
Ilustración 4 Results generated in two different case studies	9
Ilustración 5 Ejemplo de generación de una red GAN	19
Ilustración 6 Gráficas de pérdidas de generador y discriminador en casos de sobreentrenamiento	19
Ilustración 7 Resultados obtenidos en la generación del conjunto MNIST	25
Ilustración 8 Diagrama funcionamiento de GANs	26
Ilustración 9 Diagrama de convoluciones del modelo [16]	27
Ilustración 10 Imagen de entrada para el caso 1	37
Ilustración 11 Imagen generada del caso 1	38
Ilustración 12 Fallos en la generación del caso 1	39
Ilustración 13 Evolución del entrenamiento en imágenes 512x512 en el caso 1	39
Ilustración 14 Ejemplo imagen utilizada para el caso 2	40
Ilustración 15 Generación ruidosa de los primeros intentos del caso 2	41
Ilustración 16 Imágenes generadas del caso 2	42
Ilustración 17 Representación de explosión de gradiente en gráfica de pérdidas	42
Ilustración 18 Ejemplo imagen de entrada del generador con demanda y callejero	44
Ilustración 19 Imágenes generadas en el caso 3	45
Ilustración 20 Ejemplo imágenes usadas para el discriminador en el caso 4	47
Ilustración 21 Evolución en el entrenamiento en el caso 4	48
Ilustración 22 Imagen generada en el caso 4	48
Ilustración 23 Explosión de gradiente y resultado	49
Ilustración 24 Problemas de sobreajuste en algunas de las imágenes generadas	49

Ilustración 25 Entrada del discriminador en el caso 5	50
Ilustración 26 Imágenes generados en el caso 6.....	52
Ilustración 27 Imágenes generadas en el caso 6	54
Ilustración 28 Comparación entre época 205 y 300 en el caso 6	55
Ilustración 29 Resultados del caso 7	57
Ilustración 30 Progreso del entrenamiento para una misma imagen de entrada	57

Índice de tablas

Tabla 1 Revisión de metodologías de generación de redes sintéticas	15
Tabla 2 Resultados obtenidos en cada caso de estudio	35
Tabla 3 Dataset del discriminador en el caso 1	36
Tabla 4 Dataset del generador en el caso 1	36
Tabla 5 Dataset del discriminador en el caso 2	40
Tabla 6 Dataset del generador en el caso 2	41
Tabla 7 Dataset del discriminador en el caso 3	43
Tabla 8 Dataset del generador en el caso 3	44
Tabla 9 Dataset del discriminador en el caso 4	46
Tabla 10 Dataset del generador en el caso 4	47
Tabla 11 Dataset del discriminador en el caso 5	50
Tabla 12 Dataset del generador en el caso 5	51
Tabla 13 Dataset del discriminador en el caso 6	53
Tabla 14 Dataset del generador en el caso 6	53
Tabla 15 Dataset del discriminador en el caso 7	56
Tabla 16 Dataset del generador en el caso 7	56

Capítulo 1. INTRODUCCIÓN

1.1 INTRODUCCIÓN

Las redes eléctricas de distribución representan la última parte del sistema eléctrico, responsable de trasladar la energía desde las subestaciones de distribución hasta los consumidores finales mediante líneas, habitualmente, de media y baja tensión. En la actualidad, estas redes están experimentando importantes transformaciones debido a la integración de nuevos elementos como la generación distribuida, el almacenamiento o la movilidad eléctrica.

Estas transformaciones hacen cada vez más necesario contar con herramientas avanzadas para diseñar, simular y validar redes eléctricas. Sin embargo, el acceso a datos reales es muy limitado, ya que las redes se consideran infraestructuras críticas y contienen información privada, lo que ha motivado el uso de redes sintéticas o test feeders que imitan el comportamiento de redes reales.

En este contexto, las Redes Generativas Antagónicas (GANs en inglés) son una alternativa innovadora. Este tipo de modelos de deep learning tiene una gran capacidad para generar datos sintéticos realistas con estructuras complejas, especialmente en creación o modificación de imágenes. Su aplicación al diseño de redes eléctricas sintéticas es especialmente prometedora, ya que permite generar topologías realistas a partir del aprendizaje de otras redes ya creadas.

En este Trabajo de Fin de Máster se explora el uso de redes GAN para la generación de redes de distribución eléctricas sintéticas. El enfoque se centra en el diseño de la estructura de la red y en la representación de sus principales elementos como líneas y transformadores. Para el entrenamiento del modelo se utilizarán redes sintéticas desarrolladas mediante una colaboración entre NREL, IIT-Comillas y MIT, lo que permitirá que el modelo aprenda patrones estructurales y topológicos característicos de los sistemas de distribución eléctrica.

El objetivo es que el modelo sea capaz de generar mapas de la red eléctrica en una zona de distribución dada, a partir de unas imágenes de callejeros disponibles en el dominio público, o sin necesidad de unos datos de entrada, pudiendo estas ser utilizadas para investigación, planificación y validación de algoritmos, incluso en contextos donde no se dispone de datos reales por motivos de privacidad.

1.2 ESTRUCTURA DEL DOCUMENTO

Este documento se organiza en seis capítulos que abarcan desde la introducción del problema hasta las conclusiones y los trabajos futuros.

En el primer capítulo se contextualiza el tema del trabajo, introduciendo la importancia actual de las redes eléctricas de distribución, la necesidad de generar redes sintéticas y la aplicación prometedora de Redes Generativas Antagónicas (GANs).

El segundo capítulo corresponde al estado de la cuestión, donde se profundiza en la necesidad de redes sintéticas, se revisan los métodos tradicionales existentes para su generación, y se describe la evolución hacia enfoques más avanzados. También se explican las tecnologías más relevantes que se utilizarán a lo largo del trabajo y se expone la motivación y los objetivos de este.

En el capítulo tres, definición del trabajo, se describe la metodología seguida a lo largo del proyecto. Se explica que en primer lugar se ha revisado el estado del arte, seguido del proceso de preprocesamiento de datos, el diseño detallado del modelo GAN, las fases de entrenamiento y finalmente los criterios y métodos utilizados para la evaluación del modelo generado.

En el capítulo cuatro se detalla la arquitectura de los modelos implementados, fijándose en particular en las características específicas tanto del generador como del discriminador. También se describe el funcionamiento de los módulos adicionales que permiten llevar a cabo la implementación completa de las redes GAN.

El capítulo cinco se muestran los resultados de siete casos de estudio distintos. Se analizan los escenarios, tanto el tipo de entrada que tiene el modelo como el tipo de representación visual y el nivel de tensión descrito. A partir de estos resultados, se discute la calidad de las redes generadas y se realiza un análisis crítico de estos.

Finalmente, en el capítulo seis, se desarrollan las conclusiones principales del trabajo. Además, se identifican y describen líneas de investigación futuras para continuar desarrollando esta línea de investigación.

Capítulo 2. ESTADO DE LA CUESTIÓN

2.1 GENERACIÓN DE REDES DE DISTRIBUCIÓN SINTÉTICAS: MÉTODOS Y ESTADO ACTUAL

2.1.1 CONTEXTO Y NECESIDAD DE REDES SINTÉTICAS

Las redes eléctricas son esenciales para llevar la electricidad desde el lugar de producción hasta el usuario final, que puede ser un hogar, una industria o un comercio. Existen dos tipos principales de redes eléctricas, las redes de transporte, que trasladan electricidad largas distancias, y las redes de distribución, que reparten esa energía a los puntos de consumo.

Estas redes se dividen en tres niveles de tensión: las redes de alta tensión, utilizadas para el transporte eléctrico, permitiendo mover la electricidad de manera eficiente en distancias largas, las redes de media tensión se encargan de distribuir la energía a nivel regional o urbano, y las de baja tensión que llegan directamente a los usuarios. Para conectar estos niveles y regular la tensión, se utilizan elementos como transformadores y subestaciones eléctricas.

El sistema eléctrico ha evolucionado mucho en los últimos años debido a la preocupación por el cambio climático y la necesidad adoptar un modelo energético más sostenible. Esto ha llevado a una rápida electrificación de sectores que antes dependían principalmente de combustibles fósiles, como el transporte o los edificios. Al mismo tiempo, se ha producido un notable incremento en la integración de recursos energéticos distribuidos (conocidos como DERs por sus siglas en inglés), como pueden ser instalaciones solares domésticas, almacenamiento de energía en baterías, vehículos eléctricos o sistemas inteligentes capaces de regular el consumo según las necesidades de la red. Todos estos elementos se conectan directamente a la red de distribución, lo que puede causar desafíos para asegurar que sigan funcionando de manera eficiente, segura y estable [1].

Esta transformación está teniendo impactos significativos tanto a nivel técnico como operativo. A nivel operativo, los DERs generan nuevos retos como la congestión local, la inversión de flujos de potencia o la necesidad de gestionar la variabilidad de la generación, lo que obliga a rediseñar los esquemas tradicionales de planificación y operación [11]. Además, el aumento en el uso de estos recursos requiere de una supervisión más detallada y dinámica, lo que incrementa la complejidad de las herramientas de gestión de la red. Desde el punto de vista económico, estos cambios implican grandes inversiones en infraestructura de red y en digitalización para garantizar la integración segura de estos nuevos elementos [9].

Para adaptarse a estos desafíos, las redes eléctricas necesitan mejorar su eficiencia y automatización, lo que está haciendo que evolucionen a redes inteligentes (smart grids). Estas redes utilizan tecnologías de comunicación y digitalización que permiten controlar en tiempo real el estado de la red y gestionar de manera más precisa la variabilidad del flujo eléctrico. Esto además de mejorar la eficiencia permite integrar mejor la generación distribuida y la implicación de los puntos de demanda [10]. Para que estas tecnologías funcionen de manera adecuada, se necesita tener herramientas avanzadas de simulación, control y planificación, capaces de hacer frente a estos nuevos retos [1].

Para poder utilizar estas herramientas, es necesario poder trabajar con modelos realistas de redes eléctricas de distribución. El problema es que los datos de redes reales suelen estar protegidos por motivos de privacidad, por ejemplo, en países como Estados Unidos, donde se consideran parte de la infraestructura crítica del país [1]. Para superar esta limitación, se ha empezado a usar test feeders, modelos sintéticos que imitan el comportamiento de redes reales que permiten hacer estudios de manera controlada.

Los primeros test feeders, como los propuestos por el IEEE, eran de pequeño tamaño y contenían información limitada, lo cual limitaba su utilidad. Con el tiempo, se han desarrollado nuevos test feeders, capaces de representar redes de distribución a gran escala, con mayor nivel de detalle. Sin embargo, aunque estos modelos son un gran avance, siguen

construyéndose mediante métodos heurísticos, lo que dificulta imitar con precisión la diversidad y complejidad de las redes reales [1].

2.1.2 TÉCNICAS PARA GENERACIÓN DE REDES SINTÉTICAS

El artículo realizado por NREL, COMILLAS y MIT, con la participación de Carlos Mateo Domingo [1], director de este proyecto, supone un gran avance en la generación de redes eléctricas sintéticas. Esta propuesta combina los sistemas creación de redes de transporte y distribución en un mismo modelo, lo que permite realizar redes sintéticas a todos los niveles de tensión. Sin embargo, este trabajo, al igual que otros enfoques similares, se basa principalmente en métodos heurísticos y simulaciones a partir de datos existentes, que, aunque efectivos, pueden presentar limitaciones en cuanto a flexibilidad, escalabilidad y capacidad de generalización.

Por otra parte, las Redes Generativas Antagónicas (GANs) han demostrado ser herramientas muy útiles en la generación de datos sintéticos como imágenes, texto y secuencias de datos estructurados. Uno de los artículos más interesantes en este campo es el trabajo de Rong Yang [2]. En este trabajo se emplean redes Graph-GANs, que, a diferencia de este proyecto, utilizan biased random walks (camino aleatorios sesgados) sobre una red para entender su estructura y generar redes similares a aquellas con las que se ha entrenado. De esta manera se respetan la conectividad y las propiedades eléctricas de las redes reales. Posteriormente, los autores comparan estas redes con redes sintéticas reales y hacen pruebas de flujos de potencia demostrando que estas redes pueden ser usadas en estudios de planificación.

En el ámbito de la generación de mapas sintéticos mediante Redes GANs, resulta interesante el trabajo de Frank Corrigan [15], quien utilizó estas redes para generar mapas ficticios a partir de imágenes de OpenStreetMap. Este enfoque presentó diversos problemas, sobre todo relacionados con la resolución de las imágenes, ya que inicialmente utilizó imágenes de 32x32 píxeles para realizar un entrenamiento en su ordenador personal. Sin embargo, la capacidad computacional necesaria fue mucho más grande que la que disponía y el dataset

no fue el suficiente para conseguir resultados positivos. Posteriormente probó a ampliar el dataset a más de 800 imágenes de 256x256 y a utilizar una mayor capacidad computacional, y tras 70,000 steps los mapas generados se empezaban a asemejar bastante a la realidad. Estas técnicas y desafíos son relevantes para la realización de este proyecto, ya que la generación de mapas detallados y realistas será crucial para modelar adecuadamente las infraestructuras eléctricas. Además, en este proyecto se enfrentarán limitaciones similares en el ámbito de la capacidad computacional y la resolución de las imágenes.

La generación de redes eléctricas sintéticas se ha estudiado mediante diferentes métodos para mantener sus características estructurales y operativas. Un enfoque inicial es el propuesto por S. J. Young et. al [3], donde se propone una metodología para la generación de redes eléctricas sintéticas a partir de modelos reales. Esta metodología comienza con la división de redes existentes en subconjuntos que conservan sus propiedades eléctricas. Luego, estos fragmentos se reensamblan con otros siguiendo criterios topológicos y operativos, consiguiendo que la red sintética refleje características realistas como las originales. El proceso de validación incluye pruebas de contingencia (n-1) para evaluar la resistencia de la red ante fallos, así como el análisis de propiedades topológicas, como la conectividad entre nodos y la eficiencia en la transmisión de energía. Con esta metodología, se han generado redes de media y alta tensión de hasta 4,469 nodos, demostrando que tiene una alta escalabilidad.

A medida que la necesidad de generar redes sintéticas más complejas y realistas ha aumentado, se han desarrollado métodos más complejos que hacen uso de modelos reales como puede ser el algoritmo Geographical Network Learner and Generator (GNLG), descrito en [7]. En esta metodología se generan redes sintéticas de alta tensión, de 138kV a 765kV. Primero se genera una distribución espacial de subestaciones mediante un modelo gaussiano, considerando geografía y demografía, para después conectar los nodos mediante un árbol de expansión con pesos ajustables. Este método es capaz de generar redes grandes como el Western Interconnection (14,302 nodos).

Siguiendo la línea de generación de redes sintéticas basadas en redes reales, M. H. Athari et. al [4] proponen una metodología basada en la estadística para mejorar la modelización de redes eléctricas sintéticas. Primero, se realiza un análisis estadístico sobre redes reales para identificar la relación entre parámetros eléctricos y niveles de tensión. Esta relación se integra en la generación de redes sintéticas, ajustando impedancias, flujos de carga y considerando información geográfica aproximada. Este método permite generar redes con niveles de tensión desde 69 kV hasta 735 kV, siendo capaz de generar redes de hasta 100,000 nodos.

Otro enfoque más sofisticado es el aprendizaje automatizado que presenta S. Soltan et. al [5], donde se describe una metodología basada en NIMBLE, que es un método de aprendizaje para generar redes eléctricas sintéticas que imitan la estructura y distribución espacial de una red real. Comienza con el análisis de propiedades de la Western Interconnection en EE. UU., identificando patrones de distribución de buses y líneas. Una vez realizado este análisis, NIMBLE genera nuevas redes manteniendo estas propiedades mediante modelos probabilísticos. Este enfoque permite crear redes de transporte sintéticas con hasta 14,430 nodos y 18,884 líneas.

Finalmente, en [6] se describe un algoritmo que genera sistemas de distribución de media tensión mediante el uso de grafos con nodos y aristas. Se utiliza un gran conjunto de datos de un distribuidor eléctrico de los Países Bajos, de los que se identifican relaciones claras en propiedades como la carga o la longitud del cable a la estructura del alimentador. El modelo generado cubre un área de distribución de redes de media tensión de 8000km².

Analizando estos enfoques, podemos ver cómo los métodos para generar redes eléctricas sintéticas han ido evolucionando junto con la necesidad de crear modelos más precisos, pasando de técnicas más simples de segmentación y reagrupación de redes reales, a modelos más complejos que utilizan estadísticas y aprendizaje automático.

Artículo	Metodología Utilizada	Baja Tensión	Media Tensión	Alta Tensión	Tamaño redes	Datos Reales o Sintéticos
“Building and validating a Large-Scale combined transmission & distribution synthetic electricity system of Texas” [1]		Si	Si	Si	46,993,633 nodos, 14M consumidores	Sintéticos
“Synthetic Active Distribution System Synthesis via Unbalanced Graph Generative Adversarial Network” [2]	Unbalanced Graph Generative Adversarial Network (UG-GAN).	Si	Si	No	X	Sintéticos
“Synthetic Power Grids from Real World Models” [3]	Fragmentación y reensamblaje de datos reales.	No	Si	Si	4,469 nodos	Reales
“Introducing Voltage-Level Dependent Parameters to Synthetic Grid Electrical Topology” [4]	Análisis estadístico de redes reales para asignar parámetros dependientes de la tensión.	No	Si	Si	100,000 nodos	Reales
“A Learning-Based Method for Generating Synthetic Power Grids” [5]	NIMBLE, basado en el aprendizaje que imita las propiedades estructurales y espaciales de una red eléctrica real.	No	No	Si	14,430 nodos	Reales
“Automated Generation Algorithm for	Identifica patrones estadísticos, modelar los sistemas como grafos,	No	Si	No	8000km ²	Reales

Synthetic Medium Voltage Radial Distribution Systems” [6]	usa esos patrones para generar sistemas sintéticos.					
“Generation of synthetic spatially embedded power grid networks” [7]	Geographical Network Learner and Generator (GNLG) que genera redes sintéticas con características similares a las de las redes reales	No	Si	Si	14,302 nodos	Sintética
Generación de redes eléctricas sintéticas mediante redes generativas antagónicas (GANs) (Este trabajo)	Red Generativa Antagónica (GAN) que genera imágenes para construir redes sintéticas eléctricas	Si	Si	Si	Según capacidad computacional	Testeada con un caso sintético, aplicable a redes reales

Tabla 1 Revisión de metodologías de generación de redes sintéticas

2.2 DESCRIPCIÓN DE LAS TECNOLOGÍAS

Las Redes Generativas Antagónicas, conocidas como GANs, son un tipo de modelo de inteligencia artificial que funcionan mediante una confrontación entre dos redes neuronales. Estas dos redes son el generador y el discriminador, y juntas crean un sistema donde el generador aprende a crear datos sintéticos muy parecidos a los datos reales, mientras que el discriminador aprende a distinguir entre los datos verdaderos y los generados.

Aplicaciones:

Las redes GANs son una herramienta muy versátil que pueden ser aplicadas a muchos ámbitos siendo capaces de generar datos que no necesariamente tienen por qué ser imágenes. Uno de los usos más relevantes es en el procesamiento médico, donde se utilizan para generar

imágenes sintéticas para practicar, mejorar la resolución de escáneres y ayudar a la detección de estructuras anatómicas. Mediante esta herramienta se puede entrenar modelos con datos diversos sin necesidad de utilizar información sensible del paciente. [12] [13]

En el ámbito del video y de visión artificial, las GANs son muy utilizadas para la mejora de resolución de imágenes y eliminación de ruido, siendo además capaces de convertir bocetos en imágenes hiperrealistas o generar texturas en ciertas zonas. También se están usando en predicción de movimiento y simulación de escenarios físicos en animación y robótica. En el mundo del audio también tienen muchas aplicaciones, siendo capaz de generar música, voces y efectos de sonido. [14]

Además, las redes GANs se utilizan mucho para generar datos sintéticos tabulares, que se utilizan para pruebas, anonimización y entrenamiento de modelos de machine learning cuando es difícil conseguir una gran variedad de datos. Esto es especialmente importante en sectores como la salud, la banca o la ciberseguridad.

Arquitectura básica:

El generador toma como entrada un vector de ruido aleatorio o una imagen u otra muestra estructurada, dependiendo del tipo de GAN utilizada. Por ejemplo, en tareas de transformación de imágenes, como pasar de unos nodos de demanda a una red sintética de baja tensión, el generador utiliza una imagen de entrada en lugar de solo ruido, y a partir de esta entrada, el generador produce una imagen. Por otro lado, el discriminador recibe tanto datos reales del conjunto de entrenamiento como datos falsos tomados del generador, y su tarea es predecir la probabilidad de que cada muestra sea real o falsa. De esta manera, la arquitectura se basa en una competición en el que el generador busca engañar al discriminador y este último actúa como juez.

Proceso de aprendizaje:

El proceso de aprendizaje se basa en una carrera entre los dos modelos. Por un lado, el discriminador quiere ser cada vez mejor para clasificar correctamente los datos reales y los generados, y por otro el generador intenta producir muestras que sean tan realistas que el

discriminador no pueda distinguirlas de las reales. Muchas veces se compara esta arquitectura con la relación entre un falsificador y un policía en la que el falsificador mejora sus técnicas para hacer falsificaciones más convincentes, mientras que el policía mejora sus habilidades para detectar estas falsificaciones.

Este modelo se entrena de forma iterativa, primero se actualizan los parámetros del discriminador para mejorar su capacidad de detección, luego se actualizan los parámetros del generador para mejorar su capacidad de engañar. Este proceso continúa hasta que el generador crea muestras que el discriminador ya no puede diferenciar entre las muestras sintéticas de las reales, devolviendo un valor de probabilidad de acierto cercano al 50%.

Función de pérdida:

Este proceso de entrenamiento se guía por una función matemática conocida como función de pérdida, que convierte esta competición entre ambos modelos en valores numéricos que se optimizan para mejorarlos. Esta función fue diseñada por Ian Goodfellow y está construida con logaritmos.

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m \left[\log D \left(\mathbf{x}^{(i)} \right) + \log \left(1 - D \left(G \left(\mathbf{z}^{(i)} \right) \right) \right) \right]$$

Ecuación 1 Función de pérdida del discriminador

En el caso del discriminador se busca maximizar la suma de dos términos, el logaritmo de la probabilidad de que los datos reales sean reconocidos como reales, y el logaritmo de la probabilidad de que los datos falsos sean reconocidos como falsos.

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log \left(1 - D \left(G \left(\mathbf{z}^{(i)} \right) \right) \right)$$

Ecuación 2 Función de pérdida del generador

En el caso del generador, se entrena para que el discriminador clasifique sus datos como reales, lo que equivale a maximizar el logaritmo de la probabilidad de que sus muestras falsas sean clasificadas como verdaderas.

Sin embargo, esta función de pérdida puede ser inestable ya que, si el discriminador mejora muy rápido, rechaza con tanta certeza las muestras falsas que el generador deja de recibir señales útiles para aprender. Para evitar esto, se usa una variante llamada Non-Saturating GAN Loss, en la que el generador ya no minimiza la función de pérdida original, sino que maximiza directamente el logaritmo de la probabilidad de que sus muestras sean clasificadas como reales, es decir, $\log(D(G(z)))$, lo que hace que mejore la estabilidad del entrenamiento al evitar que el generador se quede sin gradiente para actualizarse.

Ventajas y limitaciones:

La principal fortaleza de las GANs es la capacidad para generar datos sintéticos que tienen un nivel de realismo muy alto, sin necesidad de conocer la estructura de los datos originales. Además, son muy flexibles y pueden adaptarse a diferentes tipos de datos y tareas. Esto las hace muy útiles para aumentar conjuntos de datos, sobre todo cuando los datos reales son limitados o difíciles de obtener.

Sin embargo, estas redes también tienen limitaciones importantes. El entrenamiento puede ser muy inestable, ya que el equilibrio entre generador y discriminador es delicado y puede llevar a que uno de los modelos domine al otro y este se estanque.

Una de las fallas más comunes es el mode collapse. Esto ocurre cuando el generador aprende a producir solo una salida, independientemente de la entrada aleatoria que se le dé. Por ejemplo, si una GAN está entrenada para generar caras, deberíamos obtener caras distintas cada vez, pero en un mode collapse, el generador termina repitiendo la misma cara permanentemente. Esto sucede porque el generador encuentra una salida que logra engañar al discriminador y en lugar de explorar otras posibilidades, se limita a repetirla.



Ilustración 5 Ejemplo de generación de una red GAN

Otro problema importante es el de los gradientes que desaparecen. Esto sucede cuando el discriminador es demasiado fuerte y clasifica con tanta seguridad que las actualizaciones que recibe el generador son inútiles. Esto lleva a que la función de pérdida se sature y las actualizaciones de los pesos sean demasiado pequeñas.

El último problema que se suele dar es el de fallo en la convergencia. En este caso, a medida que el generador mejora, el discriminador pierde capacidad para distinguir entre datos reales y falsos, reduciendo su precisión hasta un 50%. En ese momento, su refuerzo deja de ser útil y puede perjudicar al generador pudiendo hacer que este vaya empeorando. Un caso de ejemplo es el de la imagen a continuación.




Ilustración 6 Gráficas de pérdidas de generador y discriminador en casos de sobreentrenamiento

2.3 HUECOS EN LA INVESTIGACIÓN

A pesar de todos los avances en el desarrollo de metodologías para la generación de redes sintéticas, existen varias áreas con margen de mejora. Uno de los principales huecos que se pueden apreciar gracias a la Tabla 1 es la escasez de métodos para generar redes sintéticas de baja tensión que sean capaces de adaptarse a la necesidad topológica que puede ocurrir en un entorno rural o urbano. Mientras que la mayoría de los métodos se centran en la media y la alta tensión, las redes de baja suelen tener más ramificaciones y tienen que adaptarse a la distribución de los usuarios finales.

Otro aspecto poco utilizado es la incorporación de callejeros y mapas urbanos como entrada del modelo. Hay algunas investigaciones que han empezado a explorar esta posibilidad, pero aún no hay muchos avances en su integración con modelos de deep learning como las GANs, y como podemos ver en el artículo [2] este enfoque podría ayudar a generar redes más coherentes con su entorno físico.

Otro vacío en estas metodologías es la generación de redes de diferentes niveles de tensión por etapas, donde se puedan generar redes de media y alta tensión utilizando como entrada una de baja. Esto tendría una gran utilidad para tener una generación más progresiva que nos permitiría evaluar mejor cada nivel.

Por último, tampoco se ha investigado en profundidad la aplicación masiva de técnicas de inteligencia artificial para imitar las estructuras de las redes reales, adaptándolas a distintas necesidades reales. La mayoría de los modelos actuales se entrenan con datasets limitados, y tienen una capacidad de generalización limitada. Sería interesante también investigar como escalar estas técnicas para que puedan cubrir redes a nivel regional o incluso nacional, integrando mapas e información sobre el consumo energético de diferentes zonas.

2.4 MOTIVACIÓN

Este proyecto se motiva en la necesidad de superar las limitaciones de acceso a datos reales de redes eléctricas, así como el avance en algoritmos de inteligencia artificial. Este trabajo

combina ambos enfoques para aportar una herramienta útil a la comunidad científica y a la industria eléctrica. Las redes GANs tienen el potencial de generar redes de distribución que reflejen de forma precisa patrones reales, lo que podría revolucionar el diseño y la validación de sistemas eléctricos.

En muchos países, los datos completos de las redes eléctricas de distribución son considerados infraestructura crítica, lo que limita su disponibilidad para la investigación y el desarrollo de nuevas posibilidades. Esto dificulta la generación de modelos y la experimentación con algoritmos para optimización y planificación de las redes.

La generación de redes sintéticas se ha convertido en una herramienta muy útil para evaluar y comparar algoritmos de manera efectiva. Estudios previos, como los de Postigo et al. [9], destacan la importancia de las redes sintéticas en la investigación de sistemas eléctricos. Los algoritmos de generación de redes sintéticas tradicionales, basados principalmente en métodos heurísticos, dependen de la codificación de reglas predefinidas para la estructura de la red. Esta metodología tiene la limitación de no capturar la complejidad y variabilidad que presentan las redes eléctricas reales.

El uso de GANs ofrece una alternativa a estos métodos al generar redes sintéticas de manera rápida y adaptativa a las características a las que se vayan a aplicar, aprendiendo directamente de estructuras de redes reales. Sin embargo, una de las principales limitaciones de los enfoques con IA viene de la carga computacional requerida para entrenar los modelos, ya que el proceso de aprendizaje de las GANs es muy costoso y requiere de GPUs o TPUs con mucha capacidad para poder generar resultados con una resolución suficiente para capturar todos los detalles necesarios en un tiempo razonable.

Por otra parte, una de las mayores ventajas de estos modelos es su capacidad para generar grandes volúmenes de datos sintéticos en poco tiempo una vez están entrenados. Por ejemplo, en el entrenamiento de modelos de inteligencia artificial para optimización de redes, es necesario utilizar de miles o incluso millones de ejemplos con diferentes características, que sería muy difícil sin la implementación de redes sintéticas. La capacidad de generar muchas redes sintéticas de manera rápida y con unas características reales permite

hacer pruebas con algoritmos de optimización sobre estas, lo que facilita ajustarlos antes de implementarlos en redes reales.

2.5 ALINEACIÓN CON LOS OBJETIVOS DE DESARROLLO SOSTENIBLE (ODS)

Este proyecto contribuye a varios Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas:

ODS 7: Energía asequible y no contaminante

Este trabajo facilita la planificación y optimización de redes eléctricas, lo que puede contribuir a mejorar la eficiencia en la distribución de energía. Al generar redes eléctricas sintéticas con características reales, se pueden desarrollar y probar algoritmos de optimización que ayuden a crear estrategias que reduzcan pérdidas y maximicen la eficiencia de fuentes renovables. Esto es clave para garantizar un suministro eléctrico más estable, asequible y sostenible, especialmente en regiones donde la infraestructura energética es limitada, como sucede en zonas rurales.

ODS 9: Industria, innovación e infraestructura

Al aplicar inteligencia artificial, en particular Redes Generativas Antagónicas (GANs), para la generación de redes sintéticas, este proyecto impulsa la innovación en la planificación y desarrollo de infraestructuras eléctricas. La capacidad de simular redes realistas sin depender de datos sensibles fomenta la investigación y experimentación con nuevas estrategias de diseño

ODS 11: Ciudades y comunidades sostenibles

Este trabajo puede ayudar a desarrollar redes de distribución más eficientes, reduciendo pérdidas de energía y mejorando la calidad del suministro tanto en entornos urbanos como rurales. La disponibilidad de redes sintéticas bien modeladas facilita el análisis de estrategias

para optimizar el consumo energético en ciudades y garantizar el acceso a energía confiable en comunidades remotas.

2.6 OBJETIVOS

Desarrollar un modelo basado en redes generativas antagónicas (GANs) capaz de generar redes eléctricas de distribución sintéticas que puedan ser útiles en estudios futuros de planificación y optimización.

1. Diseñar e implementar un modelo de GANs que permita la generación automática de topologías de redes eléctricas de distribución.
2. Asegurar que las redes generadas conserven propiedades estructurales y eléctricas representativas, mediante el uso de conjuntos de datos sintéticos amplios y realistas durante el proceso de entrenamiento.
3. Incorporar distintos niveles de tensión en el modelo, permitiendo una representación más completa del sistema de distribución.
4. Evaluar el rendimiento del modelo comparándolo con otras redes sintéticas.
5. Generar un conjunto de redes sintéticas adaptadas a diferentes zonas geográficas, teniendo en cuenta la distribución espacial del callejero y la ubicación de los clientes, con el fin de reflejar las particularidades territoriales de cada región.

Capítulo 3. DEFINICIÓN DEL TRABAJO

3.1 METODOLOGÍA

3.1.1 REVISIÓN DEL ESTADO DEL ARTE Y FAMILIARIZACIÓN CON MODELOS GAN

Como primer paso, se realizó una revisión del estado del arte relacionada con la generación de redes eléctricas sintéticas. Esta revisión abordó tanto las metodologías existentes, los niveles de tensión considerados en diferentes trabajos, así como las limitaciones de los enfoques desarrollados en cada uno.

Paralelamente, se estudió la aplicación de las Redes GANs en ámbitos similares, analizando las arquitecturas empleadas, técnicas de entrenamiento y librerías que han demostrado buenos resultados en tareas de generación de imágenes. Este paso fue esencial para sentar una base sólida antes de pasar al diseño de modelos aplicados específicamente a redes eléctricas.

Como parte del proceso de familiarización con este tipo de modelos, se llevaron a cabo pruebas preliminares con el conjunto de datos MNIST, enfocado en la generación de dígitos escritos a mano. Estas pruebas sirvieron para familiarizarse con la dinámica de entrenamiento de las GANs, el ajuste de hiperparámetros, la interpretación de las imágenes generadas y el análisis de estabilidad del entrenamiento del generador y discriminador.

Este proceso de experimentación fue muy importante para establecer una base sólida antes de pasar al diseño de modelos aplicados específicamente a redes eléctricas.




Ilustración 7 Resultados obtenidos en la generación del conjunto MNIST

3.1.2 PREPROCESAMIENTO DE DATOS

El conjunto de datos utilizado en este proyecto está compuesto por imágenes generadas a partir de redes eléctricas reales, extraídas mediante el software QGIS. Para asegurar la validez de estas imágenes, se aplicó un proceso de recorte automático, con el objetivo de centrar las imágenes en las zonas donde aparecen nodos eléctricos y evitar regiones vacías o excesivamente blancas, que podrían introducir ruido o sesgos en el entrenamiento.

Inicialmente, se trabajó con imágenes en escala de grises, ya que reducen el coste computacional al requerir de un solo canal en vez de tres, y permitían validar rápidamente la arquitectura básica de la red. A medida que el proyecto progresó y se optimizó el modelo, se pasó al uso de imágenes a color, lo cual permitió capturar más información sobre la estructura y topología de las redes eléctricas.

El tamaño de las imágenes fue un parámetro que evolucionó a lo largo del proyecto. En las primeras fases, se utilizaron resoluciones reducidas de 64×64 píxeles, lo que permitía entrenar más rápidamente y comprobar el funcionamiento correcto de la red con un coste computacional bajo. A medida que el modelo fue mejorando se adoptaron resoluciones intermedias como 128×128 y 256×256 , que ofrecían un mayor nivel de detalle, especialmente para redes de media tensión. Finalmente, en algunos experimentos se emplearon imágenes de hasta 512×512 píxeles para generar imágenes que pudieran abarcar una mayor área de la red sin perder detalles. Este aumento de resolución requirió algunos

cambios en el modelo, siendo necesarias capas adicionales de convolución para poder escalar linealmente las imágenes hasta el tamaño final.

3.1.3 DISEÑO DEL MODELO

El modelo desarrollado se basa en una arquitectura de red generativa adversarial (GAN), compuesta por un generador y un discriminador. Ambos modelos se diseñaron con el objetivo de aprender y reproducir la estructura compleja de redes eléctricas reales representadas en imágenes.

A continuación, se presenta un esquema general que ilustra el funcionamiento conjunto de la GAN. El generador toma como entrada un vector aleatorio (ruido o imagen codificada) y produce una imagen sintética. Esta imagen es evaluada por el discriminador, que determina si corresponde a un ejemplo real del conjunto de entrenamiento o si ha sido generada artificialmente. La interacción competitiva entre ambos modelos permite mejorar progresivamente la calidad de las imágenes generadas.




Ilustración 8 Diagrama funcionamiento de GANs

El generador tiene una estructura de encoder-decoder, que facilita reducir la imagen o el ruido de entrada a un nivel muy simple y posteriormente su reconstrucción con el nivel de detalle buscado. Esta arquitectura simétrica es muy útil cuando se utilizan datos con estructuras topológicas ya que contribuye a mantener las características espaciales durante la generación. A lo largo del proyecto, esta estructura se amplió gradualmente para generar

imágenes de mayor resolución, siendo necesarias capas convolucionales extra que permitieran mantener el nivel de detalle necesario.

El discriminador, sigue un enfoque jerárquico basado en convoluciones, diseñado para identificar patrones en las imágenes y distinguir entre ejemplos reales y sintéticos. Su estructura le permite captar tanto características de bajo nivel como relaciones espaciales más amplias, lo cual es clave para detectar inconsistencias típicas de imágenes generadas artificialmente.

Ambos modelos utilizan funciones de activación adaptadas a su función. El generador emplea ReLU, que favorece salidas positivas y estables, ayudando a una generación progresiva de imágenes. En cambio, el discriminador utiliza LeakyReLU, que permite mantener un valor negativo. Esto ayuda a evitar que las neuronas se bloqueen y mejora la estabilidad del entrenamiento, especialmente al principio del aprendizaje.




Ilustración 9 Diagrama de convoluciones del modelo [16]

3.1.4 ENTRENAMIENTO

El proceso de entrenamiento se fue ajustando para mantener un equilibrio entre el generador y el discriminador, algo esencial en arquitecturas GAN. Si uno de los modelos aprende mucho más rápido que el otro, puede impedir el progreso de ambos, especialmente si el generador se ve muy superado empezará a dar steps muy grandes, lo que suele traducirse en imágenes de baja calidad, colapso del modo o inestabilidad general. Para mitigar este riesgo, se optó por entrenar el generador dos veces por cada actualización del discriminador, y se le asignó una tasa de aprendizaje superior. De este modo, se favoreció que ambos modelos progresaran a un ritmo similar y se evitó que el discriminador se volviera demasiado eficaz demasiado pronto.

Se utilizó un batch size de 16, tras descartar otros mayores como 32 o 64 debido a limitaciones computacionales, que afectaban negativamente al rendimiento del modelo. Sin embargo, con una mayor capacidad computacional, sería viable entrenar con batch sizes más grandes, lo que reduciría el número de épocas necesarias y contribuiría a un aprendizaje más estable y rápido.

El número de épocas varió en función del conjunto de datos y del tamaño de las imágenes generadas, aunque en la mayoría de las pruebas se necesitaron alrededor de 600 épocas hasta que las imágenes generadas disponían de una calidad suficiente. Para evitar el sobreentrenamiento, se monitorizaron las funciones de pérdida del generador y del discriminador en una gráfica para ver si uno de los dos era superado por el otro y cuando ocurría esto, así como la calidad visual de las imágenes generadas guardando una muestra cada cinco épocas. En algunos casos, el entrenamiento se interrumpía si se observaba una regresión en la calidad de la salida o una inestabilidad en las pérdidas.

Se empleó el optimizador Adam, con parámetros β_1 entre 0.5 y 0.6, y $\beta_2=0.999$, siguiendo trabajos encontrados en la literatura estudiada sobre las GANs. Estos dos valores controlan como se actualiza el modelo. β_1 controla la inercia del promedio de los gradientes, por lo que reducirlo permite que el modelo se adapte más rápido a cambios, lo cual es útil en entornos de entrenamiento inestables comunes en las GANs. Por otro lado, una β_2 alta como

0.999 ayuda a que los cambios en los pesos sean más suaves y estables, reduciendo los cambios bruscos entre épocas.

Se usó una función de pérdida de entropía con logits, que ayuda al modelo a aprender si una red es real o generada. Esta función compara la salida del discriminador con la respuesta correcta y le dice qué tan lejos está del resultado esperado. Esta versión de la función es más estable, especialmente al principio, cuando el generador todavía no produce redes realistas mejorando el aprendizaje de ambas redes.

El progreso del modelo se guardó automáticamente cada cinco épocas, y se conservaron todos los resultados generados durante la última época, facilitando el análisis cualitativo de las redes generadas. Los hiperparámetros se ajustaron mediante prueba y error, teniendo en cuenta tanto la estabilidad del entrenamiento como la fidelidad y variedad de las redes generadas.

3.1.5 EVALUACIÓN

La evaluación del modelo se centró en el análisis cualitativo de las imágenes generadas, dado que uno de los principales objetivos era que las redes sintéticas resultaran coherentes y realistas en comparación con las redes eléctricas reales que se tomaron mediante el uso de QGIS.

Durante el entrenamiento, se realizaba un seguimiento continuo de la evolución de las imágenes generadas en cada época, lo que permitía identificar en qué punto del entrenamiento el modelo comenzaba a producir los mejores resultados sin llegar a un sobreentrenamiento o a una explosión de gradiente. Este análisis también ayudaba a ajustar el número óptimo de épocas, incrementándolo o reduciéndolo según si la calidad desmejoraba a partir de cierto punto o no llegaba al nivel deseado.

Una vez finalizado cada entrenamiento se revisaban las imágenes generadas en la última época. El objetivo era ver topologías similares a las de las imágenes reales, disposición clara de nodos de demanda, un número apropiado de transformadores, grosores consistentes a lo largo de las líneas, uso correcto de colores y una disposición estructural creíble. Si la mayoría

de las imágenes generadas no cumplían con estos criterios, significaba que era un entrenamiento incorrecto, lo que se intentaba corregir ajustando un poco los parámetros.

Además de la evaluación visual de las imágenes generadas, se monitoreaban las curvas de pérdida del generador y del discriminador. Esto ayudaba a confirmar si el entrenamiento había sido parejo entre ambos, o si uno había sido dominado por el otro impidiendo su evolución. Otra cosa que se tenía en cuenta era evitar el sobre ajuste, un problema que se repitió a lo largo del proyecto, que era claro cuando el modelo generaba imágenes iguales entre sí en la misma época o incluso copias de las imágenes reales.

Capítulo 4. MODELO DESARROLLADO

El código desarrollado implementa una Red Generativa Antagónica (GAN) utilizando la librería PyTorch, con el objetivo de generar datos sintéticos que reproduzcan las propiedades estadísticas de un conjunto de datos reales. La arquitectura del código está compuesta por dos redes neuronales enfrentadas —un generador y un discriminador— que se entrenan de forma competitiva para lograr que las muestras sintéticas resulten indistinguibles de las reales.

Durante la fase inicial del proyecto se realizó una implementación preliminar de generación de imágenes más simples utilizando TensorFlow, que es otra de las librerías más extendidas en el campo del deep-learning. Sin embargo, cuando se empezaron a generar las primeras redes sintéticas se observó que PyTorch ofrecía un entorno más eficiente y flexible, particularmente útil para un trabajo tan iterativo y exploratorio. Su diseño del generador y del discriminador facilita la depuración y permite modificar arquitecturas de manera sencilla para modificar la red que facilitó pasar de tener ruido como entrada a imágenes de redes reales. Además, la sintaxis más parecida a Python junto con una mayor cantidad de documentación favoreció la construcción y la claridad del código. Por estos motivos, se decidió finalmente utilizar PyTorch como base para toda la implementación.

El código se desarrolló de manera modular y consta de seis bloques principales:

1. Carga y procesamiento de datos:

El conjunto de imágenes reales se ajusta al tamaño deseado, se transforma en tensores numéricos adecuados para ser procesados por las redes neuronales. Se aplica una normalización al rango $[0,1]$, lo cual mejora la estabilidad durante el entrenamiento. Además, se utiliza un DataLoader para facilitar el muestreo en mini-lotes de forma eficiente durante cada época. En un momento inicial, la baja eficiencia del código hacía que procesar las imágenes en tres canales RGB fuera muy exigente, por lo que también se usaron versiones en escala de grises.

2. Definición del discriminador:

El discriminador es la red encargada de distinguir entre imágenes reales y aquellas generadas por el modelo. Funciona de forma opuesta al generador: en lugar de crear imágenes a partir de vectores, toma como entrada una imagen y la va reduciendo progresivamente en tamaño a través de varias capas de convolución. Estas capas aplican filtros que extraen características importantes de la imagen, reduciendo su resolución mediante stride mayor que 1.

Cada capa convolucional está seguida por una función de activación LeakyReLU, que permite mantener el flujo de gradientes incluso para valores negativos, mejorando el aprendizaje. Además, se utiliza normalización por lotes (BatchNorm2d) para estabilizar el entrenamiento y facilitar la convergencia.

Después de estas transformaciones, la red aísla las características más representativas y las aplana usando una capa completamente conectada (Linear). Finalmente, esta salida se pasa por una función sigmoid que devuelve un valor entre 0 y 1, representando la probabilidad de que la imagen sea real.

3. Definición del generador:

El generador es la red encargada de crear imágenes sintéticas que se parezcan lo más posible a las reales. A diferencia del discriminador, que reduce una imagen para clasificarla, el generador realiza el proceso inverso: parte de una entrada de baja dimensión y va aumentando progresivamente la resolución mediante capas de deconvolución (ConvTranspose2d), reconstruyendo una imagen completa. Se han hecho dos variantes del generador, una que recibe como entrada un vector de ruido aleatorio y otro que toma una imagen.

La primera variante recibe un vector de ruido aleatorio, que se proyecta primero con una capa completamente conectada (Linear) y luego se redimensiona a un pequeño mapa de características inicial. A partir de ahí, el generador utiliza varias capas de convolución para ir aumentando el tamaño de la imagen: de 4×4 a la calidad deseada, 512×512 o 256×256 .

Durante este proceso, se incluyen bloques residuales que permiten que la información fluya mejor a través de la red, favoreciendo la generación de detalles más coherentes.

En el otro modelo recibe una imagen de la misma resolución de la que se desea generar, de un nivel de tensión inferior o con nodos de demanda y callejero. En este caso, se utilizan unas capas de convolución que actúan como codificador que reducen la resolución y sacan las características más importantes de la imagen. Luego, estas características se reconstruyen mediante capas de deconvolución que actúan como decodificador, recuperando paso a paso la resolución original.

4. Funciones de pérdida y optimización

Para entrenar correctamente la GAN, se emplean funciones de pérdida ajustadas para reflejar el objetivo de cada red, siendo que el generador intenta engañar al discriminador, mientras que el discriminador intenta identificar si una imagen es real o falsa. En este proyecto se utilizó la función BCEWithLogitsLoss de PyTorch, que dio mejores resultados que aplicar sigmoid seguido de BCELoss por separado como se había visto en proyectos anteriores.

Se definieron dos funciones de pérdida, `real_loss` y `fake_loss`. Ambas toman como entrada la salida del discriminador y la convierten en probabilidades entre 0 y 1 para compararlas con las etiquetas. La función `real_loss` se utiliza cuando el discriminador evalúa imágenes reales, y cuanto más seguro este el discriminador de que es una imagen real más cerca estará la probabilidad de 1. Para evitar que el discriminador aprenda más rápido que el generador, un problema común en estos proyectos, se utiliza label smoothing, reemplazando el valor 1.0 por 0.9, lo cual ayuda a prevenir que el discriminador se vuelva demasiado confiado y domine al generador, lo cual dificulta la mejora del generador. Por otro lado, la función `fake_loss` se aplica cuando el discriminador evalúa imágenes sintéticas generadas por la red generadora. En este caso, cuando mejor evalúa si la imagen es falsa, más cercano el resultado a 0, lo que indica que el discriminador debería clasificarlas como falsas.

5. Bucle de entrenamiento

El ciclo de entrenamiento de esta red está diseñado para equilibrar el aprendizaje entre el generador y el discriminador y que ninguno supere mucho al otro. En cada época, se recorren lotes de imágenes que se normalizan y se utilizan para entrenar primero al discriminador. Este evalúa tanto las imágenes reales como las generadas, calculando una pérdida por cada caso, una pérdida real para las imágenes verdaderas y una pérdida falsa para las imágenes sintéticas. Estas dos se suman para ajustar los parámetros del discriminador, permitiéndole mejorar su capacidad para distinguir entre lo real y lo generado.

Para evitar que el discriminador se vuelva demasiado fuerte y dificulte el aprendizaje del generador, solo se actualiza cada dos pasos. De este modo, se le da al generador la oportunidad de mejorar sin quedar siempre atrás sin posibilidad de engañar al discriminador. Además, los optimizadores para ambas redes se ajustan con parámetros como la tasa de aprendizaje y el momentum, de forma que ambos modelos aprendan a un ritmo similar.

Tras actualizar el discriminador, se entrena el generador. Para esto, se generan imágenes falsas a partir de imágenes reales, y se pasan por el discriminador. La pérdida se calcula como si se quisiera que el discriminador creyera que las imágenes falsas son reales. El resultado de la función de error se usa para ajustar los parámetros del generador, mejorando su capacidad para engañar al discriminador.

6. Registro de resultados y evaluación

A lo largo del entrenamiento se registran las funciones de pérdida del generador y del discriminador para cada época, lo que permite realizar un seguimiento visual del proceso de aprendizaje. Esto también facilita la detección de problemas como las ventajas del generador sobre el discriminador o viceversa. Además, cada 5 épocas se guarda una muestra visual del progreso del generador, permitiendo observar cómo evoluciona la calidad de las imágenes a lo largo del tiempo, de esta manera evitando sobreentrenar el modelo. Al finalizar el entrenamiento, se almacenan todas las imágenes generadas en la última época para su posterior visualización.

Capítulo 5. ANÁLISIS DE RESULTADOS

5.1 RESULTADOS

En esta sección se presentan los resultados de los diferentes procesos de entrenamiento de las GANs utilizando diferentes parámetros, conjuntos de datos y números de épocas. Cada intento se evalúa mediante un análisis cualitativo y visual de las imágenes generadas en distintas etapas. Se mostrarán tanto los avances como los intentos fallidos que aportaron aprendizajes clave, explicando cómo se ajustó el modelo en respuesta a dichos errores.

Los resultados se analizan desde dos perspectivas principales: visual, evaluando la claridad y definición de las imágenes; y topológica, considerando la presencia coherente de nodos y ramas en la red generada. En los casos más exitosos y representativos, se describirá la evolución del modelo a lo largo de las épocas.

Solo se mostrarán algunos resultados de cada experimento, ya que muchos intentos no se conservaron debido a limitaciones de memoria o por no aportar información relevante. A medida que el proyecto avanzó y se mejoró el código, los resultados obtenidos fueron progresivamente más precisos, por lo que se espera observar una mejora general en la calidad de las imágenes a lo largo del tiempo.

Tensión	Entrada	Color	BT	MT	AT
Todos los niveles	Ruido	B/N	X	X	X
	Ruido	Color	X	X	X
	Demanda+ Callejero	B/N	X	X	X
Por etapas	Ruido	Color	X		
	Ruido	Color		X	X
	Demanda+ Callejero	Color	X		
	Red baja tensión	Color		X	X

Tabla 2 Resultados obtenidos en cada caso de estudio

5.1.1 CASO 1: RED DE DISTRIBUCIÓN EN BLANCO Y NEGRO (SIN IMÁGENES DE ENTRADA)

Descripción

Este primer caso de estudio se centra en la generación de redes de distribución sintéticas en un formato simple: imágenes en blanco y negro que representan la topología general del sistema. En este enfoque, la entrada al modelo es un vector de ruido aleatorio, y la red genera una imagen estructurada que simula la arquitectura de una red de distribución. No se hace distinción entre diferentes niveles de tensión ni se incorpora información geográfica o de demanda. Las líneas de distribución y los transformadores se representan de forma unificada, sin diferenciar entre redes de media o baja tensión.

Dataset utilizado en el discriminador

Formato	Blanco y negro
Nivel tensión	Alta, media y baja sin distinción de grosor
Tipo de red	Monofásica con transformadores
Tamaño del dataset	516
Tamaño imágenes	256x256 y 512x512

Tabla 3 Dataset del discriminador en el caso 1

Dataset utilizado en el generador

Fuente	Ruido aleatorio
Dimensión	100
Distribución	Normal estándar (media 0, $\sigma = 1$)

Tabla 4 Dataset del generador en el caso 1




Ilustración 10 Imagen de entrada para el caso 1

5.1.1.1 Resultados del Caso 1

Este intento resultó bastante bueno, tras 500 épocas de entrenamiento el modelo generaba imágenes con una buena estructura, donde se distinguían claramente los elementos y la distribución de los componentes. En este caso, el código del modelo estaba hecho para que procesara las imágenes en un solo canal, lo que permitió reducir el coste computacional. En intentos posteriores se modificaría para habilitar el uso de múltiples canales y trabajar con imágenes a color. Aunque en las últimas épocas se seguía observando algo de ruido en el fondo, las redes generadas eran claras y estructuradas.

Con los resultados obtenidos en este intento, se confirmó que el código era funcional y que, si se iba refinando y adaptando a los diferentes datasets, se iba a poder obtener resultados cada vez mejores.




Ilustración 11 Imagen generada del caso 1

5.1.1.2 Dificultades técnicas del Caso 1

Los primeros intentos realizados con este dataset presentaron varias dificultades. En algunos casos, el modelo no lograba aprender adecuadamente la distribución de los elementos, generando imágenes confusas llenas de ruido. En otros, se producía una explosión de gradiente que impedía que el entrenamiento aprendiera de forma efectiva. Además, en una de las versiones, el modelo tendía a generar siempre la misma imagen sin importar el ruido de entrada, lo que demuestra una falta de capacidad para seguir aprendiendo.

Estas limitaciones llevaron a replantear el diseño y los parámetros del modelo, ajustando la velocidad de aprendizaje de ambos modelos, así como a ajustar los hiperparámetros y modificar el número de veces que se entrenaba al discriminador con respecto al generador.




Ilustración 12 Fallos en la generación del caso 1

En un intento posterior se aumentó la resolución de las imágenes a 512×512 , pero los resultados fueron peores y el tiempo de entrenamiento necesario para empezar a distinguir los elementos aumentó considerablemente, lo que limitó la viabilidad de esta resolución con los recursos disponibles.




Ilustración 13 Evolución del entrenamiento en imágenes 512×512 en el caso 1

5.1.2 CASO 2: RED DE DISTRIBUCIÓN CON TRANSFORMADORES A COLOR (SIN IMÁGENES DE ENTRADA)

Descripción

Este segundo caso de estudio se vuelve a centrar en la generación de redes sintéticas sin utilizar imágenes como entrada, pero con más información visual en la salida. A diferencia del caso anterior, el modelo genera imágenes a color con tres canales RGB, lo que permite

codificar diferentes tipos de elementos dentro de la red. Las líneas de distribución siguen representándose en negro y sin distinción de grosor entre niveles de tensión, pero se añaden círculos amarillos para indicar la ubicación de transformadores y puntos adicionales para representar nodos de demanda.

Dataset utilizado en el discriminador

Formato	Imagen a color (RGB)
Nivel tensión	Alta, media y baja sin distinción de grosor
Tipo de red	Monofásica con transformadores y nodos de demanda
Tamaño del dataset	2456
Tamaño imágenes	256x256

Tabla 5 Dataset del discriminador en el caso 2




Ilustración 14 Ejemplo imagen utilizada para el caso 2

Dataset utilizado en el generador

Fuente	Ruido aleatorio
Dimensión	100

Distribución	Normal estándar (media 0, $\sigma = 1$)
--------------	--

Tabla 6 Dataset del generador en el caso 2

5.1.2.1 Resultados del Caso 2

Este fue el primer intento de generación a color, enfocado en representar redes de baja tensión con mayor claridad para distinguir mejor los transformadores. El progreso del modelo siguió un patrón típico donde, al principio, las imágenes eran muy ruidosas y no se distinguía ninguna estructura reconocible más allá de los colores presentes en las imágenes del dataset.




Ilustración 15 Generación ruidosa de los primeros intentos del caso 2

A medida que avanzaba el entrenamiento, comenzaron a aparecer formas que recordaban a segmentos de líneas de tensión y algunos puntos aislados con color, lo cual indicaba que el modelo estaba empezando a aprender. En las últimas épocas, aunque el color amarillo correspondiente a los transformadores seguía presente, muchas de las estructuras generadas perdían definición. Aun así, esta versión representó un avance respecto a los intentos en blanco y negro, y sirvió como base para posteriores mejoras.




Ilustración 16 Imágenes generada del caso 2

5.1.2.2 Dificultades técnicas del Caso 2

Durante el proceso de entrenamiento se produjo una explosión de gradientes que deterioró progresivamente la calidad de las imágenes generadas, impidiendo que el modelo siguiera mejorando. Este fallo técnico hizo que el generador dejara de producir variaciones significativas en la salida, afectando especialmente la claridad de las estructuras representadas.




Ilustración 17 Representación de explosión de gradiente en gráfica de pérdidas

Para abordar este problema, se ajustaron varios parámetros del modelo y se introdujeron cambios en el código. Estas modificaciones permitieron solucionar la explosión de gradiente y mejorar la estabilidad del entrenamiento. Sin embargo, aunque se logró evitar este fallo,

las imágenes generadas en estos intentos posteriores no llegaron a alcanzar el nivel de claridad que se había conseguido previamente con imágenes en blanco y negro.

5.1.3 CASO 3: RED DE TENSIÓN EN BLANCO Y NEGRO (CON IMÁGENES DE ENTRADA)

Descripción

En este caso de estudio, se introduce por primera vez una entrada con contenido geoespacial al generador: imágenes de entrada que actúan como base, compuestas por puntos que representan nodos de demanda reales y puntos más pequeños que simulan la estructura del callejero. El objetivo es que la red GAN aprenda a diseñar topologías de red con sentido utilizando la disposición real de la demanda, generando salidas similares a las del Caso 1.

Este caso es bastante importante para avanzar hacia modelos más prácticos, ya que permite condicionar la generación de redes a las limitaciones y restricciones de un entorno real. El dataset utilizado en el generador en este intento sirve además como entrada en varios de los casos posteriores.

Imagen entrada utilizada en el discriminador

Formato	Blanco y negro
Nivel tensión	Alta, media y baja sin distinción de grosor
Tipo de red	Monofásica con transformadores
Tamaño del dataset	516
Tamaño imágenes	256x256

Tabla 7 Dataset del discriminador en el caso 3

Imagen utilizada en el generador

Formato	Blanco y negro
Nivel tensión	Demanda
Tipo de red	Nodos de demanda reales
Tamaño del dataset	2045
Tamaño imágenes	256x256

Tabla 8 Dataset del generador en el caso 3



Ilustración 18 Ejemplo imagen de entrada del generador con demanda y callejero

5.1.3.1 Resultados del Caso 3




Ilustración 19 Imágenes generadas en el caso 3

Este intento resultó bastante exitoso, confirmando que el código era válido para esta arquitectura en la que se utiliza una imagen de entrada en lugar de un vector de ruido. Los resultados generados son visualmente similares a los casos reales, con los elementos adecuados y una topología coherente. Aunque esta prueba se realizó en un solo canal, lo que simplifica el problema, los buenos resultados indican que es una línea prometedora incluso de cara a intentos futuros con imágenes en color y mayor complejidad.

5.1.3.2 Dificultades técnicas del Caso 3

A diferencia de otros intentos anteriores, este caso no presentó problemas críticos como explosión de gradientes o colapso del modelo. No obstante, el uso de una sola capa (canal) de imagen facilitó el aprendizaje, lo cual no asegura que los buenos resultados se mantengan al escalar a imágenes multicanal o más complejas. Además, aunque las salidas eran razonables, todavía se observaba cierta aleatoriedad en la ubicación de algunos transformadores, lo que indica que el modelo aún puede beneficiarse de más refinamiento en la arquitectura o entrenamiento.

5.1.4 CASO 4: RED DE BAJA TENSIÓN (SIN IMÁGENES DE ENTRADA)

Descripción

Este caso de estudio se centra en la generación de redes sintéticas de baja tensión, sin emplear imágenes de entrada. El modelo recibe como entrada únicamente un vector de ruido, y genera imágenes en color que representan la topología de las líneas de baja tensión junto con transformadores y nodos de demanda.

A diferencia de los casos anteriores, en esta versión se introduce una representación trifásica donde las tres fases de baja tensión se muestran mediante líneas de distinto color, rojo, azul y verde, mientras que las líneas trifásicas se representan en negro. Los transformadores se indican mediante círculos amarillos, y los nodos de demanda mediante puntos negros.

Este tipo de visualización permite al modelo aprender no solo la estructura espacial de una red de baja tensión, sino también la relación entre las distintas fases, lo cual resulta útil para el análisis y validación de algoritmos que requieren esta diferenciación. El diseño de esta red está orientado a generar datos sintéticos más detallados y técnicos, aún sin estar ligados a una zona geográfica concreta.

Dataset utilizado en el discriminador

Formato	Imagen a color (RGB)
Nivel tensión	Solo baja tensión
Tipo de red	Baja tensión con transformadores y nodos de demanda
Tamaño del dataset	1415
Resolución imágenes	256x256

Tabla 9 Dataset del discriminador en el caso 4




Ilustración 20 Ejemplo imágenes usadas para el discriminador en el caso 4

Dataset utilizado en el generador

Fuente	Ruido aleatorio
Dimensión	100
Distribución	Normal estándar (media 0, $\sigma = 1$)

Tabla 10 Dataset del generador en el caso 4

5.1.4.1 Resultados del Caso 4

Tras aplicar varios ajustes al código, el modelo fue capaz de generar imágenes de redes de baja tensión muy realistas, con líneas de tensión bien definidas y una mejor representación de los transformadores y nodos. Se modificaron las tasas de aprendizaje tanto del generador como del discriminador para equilibrarlas, reduciendo la del discriminador y entrenándolo la mitad de las veces que al generador. Esto ayudó a evitar que el discriminador dominara al generador, sin provocar el efecto contrario. Además, se introdujo la función de activación Leaky ReLU, que se mantendría en los siguientes intentos y también se implementaría en el código con imágenes de entrada, mejorando los resultados del generador.



Ilustración 21 Evolución en el entrenamiento en el caso 4

Los resultados generados fueron visualmente consistentes y técnicamente plausibles. Las líneas de tensión eran claramente distinguibles, con colores coherentes para cada fase y grosores constantes a lo largo de la imagen. Los nodos de demanda se distribuían con sentido topológico, apareciendo conectados de forma lógica a los transformadores, lo que indica que el modelo había aprendido correctamente tanto la estructura general como las relaciones entre los distintos elementos de la red.



Ilustración 22 Imagen generada en el caso 4

5.1.4.2 Dificultades técnicas del Caso 4

En este caso, los primeros resultados presentaron dificultades con la estabilidad del entrenamiento, mostrando explosiones de gradientes y líneas poco definidas, con colores de fases mezclados, como puede observarse en las imágenes que se muestran a continuación.




Ilustración 23 Explosión de gradiente y resultado

A diferencia de los casos anteriores, este dataset introduce una codificación de color más compleja, con diferentes colores para cada fase y para líneas trifásicas, lo que añade dificultad al proceso de aprendizaje. Para que el modelo consiguiera generar imágenes con suficiente claridad y coherencia topológica, fue necesario ajustar con precisión los parámetros y la arquitectura del código.

Se detectó un problema recurrente en algunas imágenes donde se repetía una misma estructura, generalmente en la zona inferior izquierda. Este comportamiento podría deberse a patrones de sobreajuste o sesgos en el dataset, donde ciertas configuraciones aparecían con mayor frecuencia y el generador las iba repitiendo al encontrar que le funcionaban para engañar al discriminador.




Ilustración 24 Problemas de sobreajuste en algunas de las imágenes generadas

5.1.5 CASO 5: RED DE MEDIA Y ALTA Tensión (SIN IMÁGENES DE ENTRADA)

Descripción

Este caso se enfoca en la generación de redes sintéticas correspondientes a los niveles de media y alta tensión, sin utilizar imágenes de entrada. Las imágenes generadas emplean un esquema de colores similar al del caso anterior: líneas rojas, azules y verdes para representar las fases individuales, y líneas negras para los tramos trifásicos. A diferencia del caso de baja tensión, aquí se introduce una diferenciación adicional mediante el grosor de las líneas, que varía según se trate de media o alta tensión, mientras que los transformadores siguen representándose como círculos amarillos.

Dataset utilizado en el discriminador

Formato	Imagen a color (RGB)
Nivel tensión	Media y alta
Tipo de red	Red de media y alta tensión con diferenciación de grosor y transformadores
Tamaño del dataset	1547
Tamaño imágenes	256x256

Tabla 11 Dataset del discriminador en el caso 5




Ilustración 25 Entrada del discriminador en el caso 5

Dataset utilizado en el generador

Fuente	Ruido aleatorio
Dimensión	100
Distribución	Normal estándar (media 0, $\sigma = 1$)

Tabla 12 Dataset del generador en el caso 5

5.1.5.1 Resultados del Caso 5

En este caso de estudio, los resultados obtenidos no alcanzaron la calidad deseada. Las imágenes generadas por el modelo mostraron formas y alguna estructura con sentido, especialmente en lo referente a los colores asignados a cada fase, siendo capaces de diferenciar correctamente entre líneas monofásicas y trifásicas. Sin embargo, la disposición espacial y topológica no resultó satisfactoria, mostrando redes poco coherentes y con mucho ruido de fondo, con líneas desconectadas o sin una distribución lógica clara. En general, aunque el modelo logró aprender ciertas características básicas como colores y tipos de líneas, no consiguió generar una topología realista para redes de media y alta tensión con ruido de entrada.

5.1.5.2 Dificultades técnicas del Caso 5

Este caso presentó diversas dificultades técnicas durante el entrenamiento, siendo la principal la falta de convergencia y estabilidad del modelo. Las imágenes obtenidas tenían un alto nivel de ruido visual, con elementos poco definidos o fragmentados, lo que indica que el generador no logró capturar adecuadamente las relaciones espaciales complejas propias de redes con diferentes niveles de tensión.

Entre las posibles causas destaca la mayor complejidad inherente a la representación simultánea de redes de media y alta tensión, que requieren no solo diferenciar colores por fases, sino también grosores específicos según los niveles de tensión. Esto generó una

dificultad adicional al modelo, que se manifestó en una mayor sensibilidad a los ajustes de hiperparámetros, especialmente las tasas de aprendizaje y la proporción de entrenamiento generador-discriminador.




Ilustración 26 Imágenes generados en el caso 6

5.1.6 CASO 6: RED DE BAJA TENSIÓN (CON IMÁGENES DE ENTRADA)

Descripción

En este caso se explora la generación de redes sintéticas de baja tensión, incorporando imágenes de entrada con información geográfica como base condicionante. A diferencia del Caso 4, donde el modelo partía de una entrada de ruido, aquí el generador recibe como entrada una imagen que representa la distribución espacial de los nodos de demanda reales y una representación simplificada del callejero local.

El objetivo de este caso es que el modelo genere redes de baja tensión adaptadas al contexto urbano representado en la imagen de entrada, manteniendo el mismo tipo de salida que en el Caso 4: imágenes a color que muestran líneas monofásicas (rojas, verdes y azules), líneas trifásicas (negras), círculos amarillos para transformadores y puntos negros para nodos de demanda.

Dataset utilizado en el discriminador

Formato	Imagen a color (RGB)
Nivel tensión	Solo baja tensión
Tipo de red	Baja tensión con transformadores y nodos de demanda
Tamaño del dataset	1415
Tamaño imágenes	256x256

Tabla 13 Dataset del discriminador en el caso 6

Dataset utilizado en el generador

Formato	Blanco y negro
Nivel tensión	Demanda
Tipo de red	Nodos de demanda reales
Tamaño del dataset	2045
Tamaño imágenes	256x256

Tabla 14 Dataset del generador en el caso 6

5.1.6.1 Resultados del Caso 6

En este caso, los resultados fueron especialmente positivos. Las imágenes generadas fueron muy superiores a las obtenidas en intentos anteriores que usaban el mismo dataset pero con ruido como entrada. La entrada con nodos de demanda y callejero permitió al generador adaptar mucho mejor la topología de las redes a la distribución de la demanda, generando líneas de tensión con más sentido y transformadores bien posicionados.

Además, se solucionó el problema de las estructuras repetidas en la salida que se había observado en otros casos. Las imágenes generadas mantenían una estructura coherente, en las que los colores, grosores y formas de las líneas eran consistentes, y los nodos de demanda se disponían de manera lógica en torno a los transformadores, mostrando una organización topológica verosímil. Este caso evidenció que el uso de imágenes de entrada mejora notablemente la calidad de las redes generadas y su realismo.




Ilustración 27 Imágenes generadas en el caso 6

5.1.6.2 Dificultades técnicas del Caso 6

A pesar de los buenos resultados, fue necesario realizar varios ajustes experimentales para encontrar el número adecuado de épocas de entrenamiento. Se observó que cuando el modelo se entrenaba durante las 650 épocas habituales, la calidad de las imágenes no solo dejaba de mejorar, sino que comenzaba a deteriorarse, introduciendo ruido visual en el fondo. Este fenómeno puede observarse en las imágenes que se generaron a diferentes etapas del entrenamiento, como las de las épocas 205 y 300, usando la misma imagen de entrada.




Ilustración 28 Comparación entre época 205 y 300 en el caso 6

Otro problema detectado fue que, en algunas imágenes generadas, aparecían muy pocas líneas de tensión. Este comportamiento podría estar relacionado con una baja densidad de nodos de demanda en la imagen de entrada, o con ciertas muestras del dataset del discriminador, en las que algunas regiones estaban poco conectadas. Aun así, este intento confirmó que el uso de imágenes de entrada aporta una mejora significativa en la coherencia topológica y la adecuación espacial de las redes generadas.

5.1.7 CASO 7: RED DE MEDIA Y ALTA TENSIÓN (CON IMÁGENES DE ENTRADA)

Descripción

Este caso de estudio representa un avance hacia la generación de redes eléctricas sintéticas de manera iterativa, en la que el modelo aprende a construir la red de media y alta tensión a partir de la disposición de una red de baja tensión existente. La entrada del generador es una imagen en color que representa la red de baja tensión como la generada en el caso 4, y el objetivo es generar una red de niveles superiores acorde a esa estructura. Esta entrada ofrece una representación completa sobre la que debe estructurarse la red sintética nueva.

Este tipo de enfoque permite evaluar la capacidad del modelo para generar estructuras de red más complejas a partir de otras de un nivel de tensión inferior, lo que puede ser

especialmente útil en tareas de planificación jerárquica donde se vayan generando redes de distribución por nivel de tensión.

Dataset utilizado en el discriminador

Formato	Imagen a color (RGB)
Nivel tensión	Media y alta
Tipo de red	Red de media y alta tensión con diferenciación de grosor y transformadores
Tamaño del dataset	1547
Tamaño imágenes	256x256

Tabla 15 Dataset del discriminador en el caso 7

Dataset utilizado en el generador

Formato	Imagen a color (RGB)
Nivel tensión	Solo baja tensión
Tipo de red	Baja tensión con transformadores y nodos de demanda
Tamaño del dataset	1415
Tamaño imágenes	256x256

Tabla 16 Dataset del generador en el caso 7

5.1.7.1 Resultados del Caso 7

En este intento, los resultados obtenidos fueron bastante buenos. Las imágenes generadas mostraban estructuras realistas, con líneas de tensión diferenciadas por grosor,

transformadores claramente identificables y una disposición topológica coherente. La red generada respetaba la estructura de la red de baja tensión proporcionada como entrada, lo que sugiere que el modelo fue capaz de aprender a construir niveles superiores de la red de manera contextual.




Ilustración 29 Resultados del caso 7

5.1.7.2 Dificultades técnicas del Caso 7

Aunque el entrenamiento fue estable desde el inicio, se observó que prolongar el número de épocas más allá de 350 no aportaba mejoras significativas en la calidad de las imágenes generadas. De hecho, a partir de ese punto comenzaba a manifestarse un incremento del ruido en el fondo, lo que sugiere un posible inicio de sobreentrenamiento. Esta situación resalta la importancia de ajustar adecuadamente el número de épocas y aplicar técnicas como la parada temprana para evitar que el modelo pierda generalización y degrade la calidad visual de las salidas.




Ilustración 30 Progreso del entrenamiento para una misma imagen de entrada

5.2 DISCUSIÓN

A lo largo de este trabajo se han desarrollado y optimizado dos enfoques diferentes para la generación de redes eléctricas sintéticas mediante Redes Generativas Antagónicas (GANs). Ambos modelos, aunque con arquitecturas ligeramente distintas, demostraron ser válidos y funcionales. Por un lado, se implementó un generador que toma imágenes como entrada, como puntos de demanda y callejeros; y por otro, un generador más común en este tipo de arquitectura, que utiliza ruido aleatorio como entrada. La comparación entre ambos ha permitido extraer conclusiones relevantes sobre su estabilidad, calidad de salida y dificultad de entrenamiento.

Los primeros intentos con imágenes en blanco y negro resultaron ser particularmente buenos y estables, ya que al trabajar con un solo canal siendo la imagen en escala de grises, el modelo podía centrarse en aprender patrones estructurales sin el reto adicional de detectar y utilizar correctamente los diferentes colores. En estos casos no se observaron problemas de gradientes ni inestabilidades notables, y los resultados fueron bastante buenos desde fases tempranas del entrenamiento. Esto demuestra que trabajar con imágenes más simples facilita la convergencia del modelo, especialmente en arquitecturas GAN sensibles a desequilibrios entre el generador y el discriminador.

Al pasar a imágenes a color, la complejidad aumentó significativamente, particularmente en los modelos donde el generador usaba ruido como entrada. En estos casos, el entrenamiento se volvió más inestable y fue necesario ajustar cuidadosamente parámetros como la tasa de aprendizaje de ambas redes y la proporción de actualizaciones entre discriminador y generador. Se observó que una mala elección de estos parámetros o cambios muy drásticos causaban problemas de gradiente, dominación de una de las redes o en resultados con ruido de fondo y estructuras incoherentes. Esto se debe a que trabajar con canales de color requiere una mayor capacidad del modelo para generar relaciones espaciales precisas, además de una estabilidad que no siempre se alcanzaba fácilmente.

A pesar de estos desafíos, se consiguió entrenar con éxito ambos tipos de modelos. El enfoque basado en imágenes de entrada resultó ser más robusto y consistente en la generación de redes realistas, mostrando una mejoría en cuanto a estabilidad del entrenamiento y calidad visual. Las imágenes generadas en estos modelos conservaban los elementos (líneas, nodos, transformadores), con una topología realista. No obstante, se observó que cuando el modelo recibía imágenes de entrada con muy pocos nodos de demanda, tendía a generar redes menos realistas o con estructuras poco habituales. Esto sugiere que este enfoque es especialmente adecuado para contextos con alta densidad de carga, como ocurre en entornos urbanos.

Por otra parte, el modelo basado únicamente en ruido aleatorio también fue capaz de generar imágenes válidas y con buena definición, especialmente tras introducir mejoras como el uso de la función de activación Leaky ReLU. Sin embargo, este enfoque mostró una mayor sensibilidad al número de épocas de entrenamiento: si el modelo se entrenaba durante demasiado tiempo, se introducía ruido visual o disminuía la diversidad de las imágenes generadas. Otro fenómeno observado fue la repetición de ciertas estructuras, posiblemente atribuible a patrones frecuentes en el dataset o a la tendencia del generador de repetir algo con lo que suele engañar al discriminador.

En resumen, ambos enfoques son válidos y aportan diferentes cosas. El modelo que utiliza imágenes de entrada permite obtener salidas más estructuradas y alineadas con patrones conocidos, mientras que el modelo sin entrada puede generar una mayor variedad, siempre que se logre estabilizar adecuadamente el entrenamiento. El análisis de los resultados sugiere que el uso de imágenes en blanco y negro facilita el aprendizaje, pero que la transición a imágenes a color requiere una arquitectura más refinada y un proceso de entrenamiento más delicado, pero se pierde una gran cantidad de información si no se usa color. Aun así, los resultados obtenidos son prometedores y abren la puerta a aplicaciones prácticas tanto para generación sintética como para tareas de simulación y entrenamiento de algoritmos de optimización en redes eléctricas.

Capítulo 6. CONCLUSIONES Y TRABAJOS FUTUROS

6.1 CONCLUSIONES

Este trabajo ha demostrado que las Redes Generativas Antagónicas (GANs) son una metodología válida para generar redes eléctricas sintéticas con topologías realistas. Se han probado dos enfoques, uno basado en imágenes de entrada que condicionan el modelo, y otro basado en ruido aleatorio como entrada.

El modelo basado únicamente en ruido aleatorio no requiere datos condicionantes externos, ya que no depende de una estructura de entrada. Sin embargo, presentó mayores dificultades durante el entrenamiento, siendo más inestable y mostrando un mayor nivel de ruido en los resultados finales. El modelo con ruido aleatorio podría ser más útil en para generar redes sintéticas, pero no serviría para estudios de planificación. Se podría generar fácilmente redes sintéticas ya que no haría falta información de contorno, pero precisamente esto sería una debilidad frente al otro método ya que no tendría correspondencia con zonas reales, como si tiene el modelo con información de entrada. Por otro lado, el modelo condicionado utiliza imágenes de nodos de demanda y callejeros, o redes sintéticas de un nivel de tensión inferior, lo que le permite generar redes que se adaptan a las limitaciones y necesidades observadas en la entrada. Esto facilita la creación de redes más coherentes y estructuradas. Se puede concluir que el modelo que utiliza imágenes es particularmente útil en zonas urbanas, donde la distribución de nodos de demanda está claramente definida.

Una de principales observaciones es que los modelos con imágenes de entrada presentan una mayor estabilidad durante el entrenamiento, lo que lleva a imágenes generadas más claras, con menos ruido en el fondo y mayor coherencia topológica. Mientras que los modelos que tienen ruido aleatorio en la entrada son más sensibles a ajustes de hiperparámetros, como las tasas de aprendizaje o la proporción en el número de actualizaciones de entrenamiento entre el generador y el discriminador. Esta mayor sensibilidad puede generar problemas como

ruido visual, repetición de estructuras o baja diversidad, si no se realiza un ajuste muy preciso.

Se ha observado también que trabajar con imágenes en blanco y negro simplifica notablemente el entrenamiento de las GANs debido a la reducción del número de canales de 3 a 1, lo cual mejora la convergencia y la estabilidad. Pese a esto, utilizar imágenes a color permite incorporar más detalles sobre la red, como puede ser representar distintos tipos de líneas de tensión y transformadores. Aunque esta opción requiere más tiempo y mayor capacidad computacional, resulta indispensable cuando se busca mayor nivel de detalle en las redes sintéticas generadas.

El rendimiento de los modelos mejora notablemente cuando las imágenes del dataset de entrenamiento tienen un equilibrio entre nodos, líneas, y espacio en blanco. Si estos 3 elementos están equilibrados, se tendrá una generación óptima, mientras que en caso de estar desbalanceados y tener muchas imágenes mayormente vacías el modelo tiende a repetirse o a crear elementos sin sentido o con más ruido. Por este motivo es importante prestar mucha atención a la etapa del preprocesado y limpieza de datos. En este proyecto, el tamaño del dataset ha oscilado entre 1000 y 2000 imágenes según el caso, cantidad que ha sido suficiente para entrenar los modelos y general resultados. Sin embargo, contar con un conjunto más amplio y diverso podría haber permitido mejorar la generalización del modelo, reducir la aparición de patrones repetitivos y facilitar el entrenamiento con más capas convolucionales o con resoluciones mayores.

A lo largo de este trabajo también se han observado varias limitaciones, una de ellas siendo la dificultad que presentan los modelos para generar redes realistas en escenarios con una baja densidad de nodos de demanda, como es habitual en áreas rurales. En estos casos, las redes generadas suelen ser menos coherentes o tienden a producir nodos de demanda adicionales no realistas. Otra limitación de esta metodología es la capacidad computacional disponible, ya que trabajar con más recursos de GPU habría permitido trabajar con imágenes de mayor resolución y calidad sin tener que aumentar mucho el tiempo de entrenamiento, generando redes más detalladas y extensas, además de haber podido hacer pruebas de

entrenamiento de un mayor número de epochs. Finalmente, aunque los modelos generan imágenes visualmente realistas, no contienen parámetros técnicos, como impedancias, pérdidas o características eléctricas específicas, lo que limita su uso directo en simulaciones eléctricas avanzadas.

En conclusión, aunque la metodología tiene algunos desafíos que hay que resolver, y que quizás tenga aplicabilidad limitada al no mostrar muchos parámetros, existe un gran margen de mejora para la línea de estudio, y los resultados obtenidos son bastante positivos demostrando que las redes GAN tienen un gran potencial en la generación de redes sintéticas.

6.2 TRABAJOS FUTUROS

A pesar de los avances logrados en este proyecto, existen diversas líneas de desarrollo que podrían explorarse en el futuro para mejorar la generación de redes eléctricas sintéticas mediante redes generativas antagónicas.

1. Aumento de la capacidad computacional y mejora de la resolución:

Una de las principales limitaciones de este trabajo ha sido la capacidad computacional disponible, lo que ha condicionado el tamaño y resolución de las imágenes utilizadas. Con un mayor acceso a recursos computacionales como GPUs más potentes o clústeres de procesamiento, sería posible trabajar con imágenes de mayor resolución. Esto permitiría representar y analizar con mayor precisión redes de alta tensión, que presentan mayor complejidad estructural y mayor escala espacial.

Además, con una mayor capacidad computacional se podría aumentar el batch size lo suficiente como para utilizar los resultados obtenidos en la última época de un generador de un nivel de tensión inferior como entrada para un nivel de tensión mayor. Esta arquitectura permitiría mejorar la generación progresiva y la calidad de las redes sintéticas en diferentes niveles de tensión. Sin embargo, debido al tamaño reducido del batch size que fue necesario emplear, esta arquitectura no pudo implementarse.

2. Diferenciación geográfica:

El uso de conjuntos de datos más amplios y variados, por ejemplo, diferenciando entre redes urbanas y rurales, permitiría al modelo aprender patrones específicos de cada entorno. Esto enriquecería la capacidad del sistema para generar redes adaptadas a distintos contextos geográficos y operativos, aumentando su utilidad práctica en simulaciones realistas.

3. Experimentación con Conditional GANs:

Una mejora técnica relevante sería la introducción de Conditional GANs, que permitirían condicionar la generación a parámetros específicos como el número de nodos, la densidad de demanda o la presencia de subestaciones. Esto sería especialmente útil en modelos que trabajan sin entrada de imágenes reales, permitiendo controlar el diseño de la red según necesidades concretas.

4. Incorporación de Parámetros Eléctricos a las Redes Generadas

Una interesante investigación futura sería ampliar el modelo generativo desarrollado en este trabajo para que además de generar la distribución topológica y real de redes de distribución, incluya unos parámetros eléctricos realistas para estas. De esta manera, las redes generadas por redes GAN o otras técnicas de inteligencia artificial ofrecerían valores realistas de propiedades como la impedancia, reactancia, resistencias, pérdidas en vacío y cortocircuito y longitud de líneas. Esta ampliación permitiría tener modelos eléctricos completos que facilitarían su utilización en simulaciones avanzadas y estudios más complejos como flujos de carga o estabilidad.

5. Aplicación a otros dominios de infraestructura técnica:

La metodología mediante redes GANs podría aplicarse también a otros tipos de redes técnicas con similares necesidades topológicas, como redes de distribución de agua o gas, que comparten características similares en cuanto a nodos, ramificaciones y restricciones espaciales. El uso de estas redes podría facilitar la creación de topologías sintéticas para análisis hidráulicos, de presión o planificación de infraestructuras.

6. Desarrollo de una herramienta de análisis visual e integración en software SIG:

Un paso adicional sería el desarrollo de una herramienta que, mediante visión artificial, detecte automáticamente las estructuras presentes en las imágenes generadas y las convierta en objetos (por ejemplo, líneas de tensión de diferentes niveles, posicionamiento de transformadores etc.) en software como QGIS o similares. Esto permitiría utilizar directamente las redes generadas en estudios de planificación eléctrica, simulaciones o análisis espacial.

Capítulo 7. BIBLIOGRAFÍA

- [1] Mateo, C., Postigo, F., Elgindy, T., Birchfield, A. B., Dueñas, P., Palmintier, B., Panossian, N., Gómez, T., de Cuadra, F., Overbye, T. J., Safdarian, F., & Wallison, D. (2024). Building and validating a large-scale combined transmission & distribution synthetic electricity system of Texas. *International Journal of Electrical Power and Energy Systems*, 159, 110037. <https://doi.org/10.1016/j.ijepes.2024.110037>
- [2] Yan, R., Yuan, Y., Wang, Z., Geng, G., & Jiang, Q. (2023). Active distribution system synthesis via unbalanced graph generative adversarial network. *IEEE Transactions on Power Systems*, 38(5), 4293–4307.
- [3] Young, S. J., Makarov, Y., Diao, R., Fan, R., Huang, R., O'Brien, J., Halappanavar, M., Vallem, M., & Huang, Z. H. (2018). Synthetic power grids from real world models. Pacific Northwest National Laboratory, Richland, WA, USA.
- [4] Athari, M. H., & Wang, Z. (2019). Introducing voltage-level dependent parameters to synthetic grid electrical topology. *IEEE Transactions on Smart Grid*, 10(4), 4048–4056.
- [5] Soltan, S., Loh, A., & Zussman, G. (2019). A learning-based method for generating synthetic power grids. *IEEE Systems Journal*, 13(1), 625–634.
- [6] Schweitzer, E., Scaglione, A., Monti, A., & Pagani, G. A. (2017). Automated generation algorithm for synthetic medium voltage radial distribution systems. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 7(2), 271–284.
- [7] Soltan, S., & Zussman, G. (2016). Generation of synthetic spatially embedded power grid networks. In 2016 IEEE Power and Energy Society General Meeting (PESGM) (pp. 1–5). IEEE.
- [8] Postigo Marcos, F. E., Mateo Domingo, C., Gómez San Román, T., Palmintier, B., Hodge, B.-M., Krishnan, V., De Cuadra García, F., & Mather, B. (2017). A review of power distribution test feeders in the United States and the need for synthetic representative networks. *Energies*.
- [9] Khalid, M. (2024). Smart grids and renewable energy systems: Perspectives and grid integration challenges. *Energy Strategy Reviews*, 51, 101299.

- [10] Chaves, J. P., Cossent, R., Gómez, T., López, G., Matanza, J., Mateo, C., Rodríguez, N., & Sánchez, M. A. (2021). La digitalización de las redes eléctricas de distribución en España: Una visión desde la ingeniería. Fundación Ingenieros ICAI para el Desarrollo.
- [11] Mateo, C., Postigo, F., & Sánchez-Miralles, Á. (s.f.). Impact of distributed energy resources in the networks. En Lecture Notes (Cap. 8, pp. 1–19).
- [12] Hussain, J., Båth, M., & Ivarsson, J. (2025). Generative adversarial networks in medical image reconstruction: A systematic literature review. *Computers in Biology and Medicine*, 170, 107933. <https://doi.org/10.1016/j.compbiomed.2024.107933>
- [13] Kazeminia, S., Baur, C., Kuijper, A., van Ginneken, B., Navab, N., Albarqouni, S., & Mukhopadhyay, A. (2019). GANs for medical image analysis (Version 3). arXiv. <https://doi.org/10.48550/arXiv.1809.06222>
- [14] Tian, C., Zhang, X., Zhu, Q., Zhang, B., & Lin, J. C.-W. (2024). Generative adversarial networks for image super-resolution: A survey (Version 4). arXiv. <https://doi.org/10.48550/arXiv.2204.13620>
- [15] Corrigan, F. (2020, 26 de noviembre). Creating fake maps with GANs. Towards Data Science. <https://towardsdatascience.com/creating-fake-maps-with-gans-42ad1fc94d97>
- [16] Mismar, F. B., Gündoğan, A., Kaya, A. Ö., & Chistyakov, O. (2023). Deep learning for multi-user proactive beam handoff: A 6G application. *IEEE Access*, 11, 46271–46282. <https://doi.org/10.1109/ACCESS.2023.3274810>