

Trabajo de Fin de Máster
julio, 2024

Optimización de Redes de Distribución Energética Mediante Inteligencia Artificial: Un Enfoque de Simulación

Autor: Erick José Mercado Hernández
Director: Dr. Juan Manuel Corchado Rodríguez
Co-Director: Dr. Alfonso Gonzales Briones



Departamento de Informática y Automática
Universidad de Salamanca

Revisado por:

Dr. Juan Manuel Corchado Rodríguez
Dr. Alfonso Gonzales Briones

Información del Autor:

Erick José Mercado Hernández
Alumno Master En Sistemas Inteligentes
Universidad de Salamanca
erickmred@usal.es

Información de los Directores:

D. Juan Manuel Corchado Rodríguez
Rector Magnífico de la Universidad de Salamanca
Universidad de Salamanca
corchado@usal.es

D. Alfonso Gonzales Briones
Profesor Titular de Ciencias de la Computación e Inteligencia Artificial
Universidad de Salamanca
alfonsogb@usal.es

Declaración de autoría

Declaro que he redactado el Trabajo de Fin de Máster (TFM) titulado “Optimización de Redes de Distribución Energética Mediante Inteligencia Artificial: Un Enfoque de Simulación” del Máster Universitario en Sistemas Inteligentes de la Universidad de Salamanca en el segundo semestre del curso académico 2023/24 de forma autónoma, con la ayuda de las fuentes y la literatura citadas en la bibliografía, y que he identificado como tales todas las partes tomadas de las fuentes y de la literatura indicada, textualmente o conforme a su sentido.

El trabajo parte de una idea original propia, que se ha desarrollado bajo la dirección de Juan Manuel Corchado Rodríguez y Alfonso Gonzales Briones y, en consecuencia, comparto con ellos la propiedad intelectual de los resultados alcanzados.

En Salamanca, a 12 de julio de 2024

Erick José Mercado Hernández

Resumen

Este trabajo de investigación examina la optimización de redes de distribución energética mediante la incorporación de técnicas de inteligencia artificial y el uso de herramientas de simulación avanzadas basadas en motores de videojuegos, específicamente Unity. Se destaca la aplicación del aprendizaje por refuerzo, junto con otras técnicas de IA, para la mejora en la eficiencia y manejo de las cargas energéticas en condiciones dinámicas y variables. Este enfoque permite no solo anticipar las fluctuaciones en la demanda y la oferta de energía, sino también adaptar las estrategias de operación en tiempo real para maximizar la eficiencia del sistema.

A través de un proceso de simulación, se han probado diversas estrategias de gestión energética. Estas simulaciones proporcionan un ambiente seguro y controlado para experimentar con diferentes configuraciones y escenarios sin los riesgos asociados con las pruebas en sistemas reales.

Los resultados obtenidos indican que la implementación de la IA en la gestión de redes energéticas puede conducir a una notable reducción de pérdidas energéticas y a una gestión más eficiente de la carga. Este aspecto es particularmente relevante dado el creciente enfoque hacia la sostenibilidad y la necesidad de sistemas energéticos que puedan adaptarse y manejar eficazmente recursos renovables.

Palabras clave: Inteligencia Artificial, Simulación, Redes de Distribución Energética, Aprendizaje por Refuerzo, Energías Renovables.

Abstract

The focus of this study is on the optimisation of energy distribution networks through the application of advanced artificial intelligence (AI) techniques and the use of video game engines such as Unity for simulation. It explores methods such as reinforcement learning to improve the efficiency and management of loads under dynamic and variable conditions.

Simulations allow testing and validation of energy management strategies in a safe and controlled environment, providing valuable insights for practical implementation. The results demonstrate that the combination of AI and simulation can reduce energy losses and effectively accommodate renewable energy integration.

Keywords: Artificial Intelligence, Simulation, Energy Distribution Networks, Reinforcement Learning, Renewable Energies

Índice

Índice de figuras	IV
Índice de tablas	V
1. Introducción	1
2. Estado del Arte	3
2.1. Introducción	3
2.2. Redes de Distribución Energética	3
2.3. Técnicas de Inteligencia Artificial Aplicadas a la Energía	3
2.4. Simulación de Redes Energéticas	4
2.5. Tecnologías y Herramientas Utilizadas	4
3. Revisión sistemática de literatura	5
3.1. Metodología: Revisión Sistemática de Literatura	6
3.1.1. Optimización con IA:	7
3.1.2. Uso de motores de videojuegos:	10
3.1.3. Energías Renovables	13
3.2. Metodología: Búsqueda Ad Hoc	16
3.2.1. Hallazgos de la Búsqueda Ad Hoc	16
3.2.2. Tendencias Principales Identificadas	16
3.2.3. Artículo de Referencia	17
3.2.4. Conclusión	18
3.3. Discusión	18
3.4. Conclusión	19
4. Caso de estudio	19
4.1. Desarrollo del Sandbox	19
4.2. Datos Seleccionados	25
4.3. Implementación de Algoritmos de IA	26
4.3.1. Aprendizaje por Refuerzo	30
4.4. Evaluación del Modelo	31
4.4.1. Proceso de Evaluación	31
4.4.2. <i>Dataset</i> de Resultados y Análisis	31
4.4.3. Métricas de Evaluación	34
4.5. Resultados del Caso de Estudio	37
4.5.1. Eficiencia Energética	37
4.5.2. Reducción de Pérdidas	37
4.5.3. Adaptabilidad del Sistema	37

4.5.4. Análisis de Gráficos y Datos	37
4.5.5. Implementación de Algoritmos de IA	38
4.5.6. Estadísticas Descriptivas y Correlaciones	40
4.6. Discusión	41
4.7. Conclusión del Caso de Estudio	41
5. Conclusiones	41
Referencias	43

Índice de figuras

1.	Frecuencias de palabras clave en IA	7
2.	Red de coocurrencia IA	9
3.	Frecuencia de palabras clave Motores Gráficos	10
4.	Red de concurrencia de los Motores Gráficos	12
5.	Frecuencia de palabras claves en Energías Renovables	13
6.	Red de coocurrencia en terminos relacionados con la energias renovables	15
7.	Sandbox de unity	20
8.	Modelo aerogenerador	20
9.	Inspertor de configuración del <i>microgrid Manager</i>	21
10.	Inspector de configuración del <i>Wind Manager</i>	21
11.	<i>Heigthmap</i> de la isla	22
12.	Modelo 3D de la isla	23
13.	Modelos 3D simples de consumidores	23
14.	Diagrama esquemático de los diferentes tipos de consumidores y su integración en la red de distribución energética [10]	25
15.	Rosa de los vientos	26
16.	Curva Teorica e Ideal del aerogenerador	27
17.	Salida de potencia y velocidad de giro frente a la velocidad de viento	27
18.	Comparativa de la potencia activa y la potencia ideal de la generación	28
19.	Interfaz Unity MLAGents	28
20.	Diagrama Ilustrativo del aprendizaje por refuerzo [27]	30
21.	Diagrama de flujo del proceso de implementación de algoritmos de IA en la simulación de la red energética [25].	31
22.	Diagrama de Dispersión de Velocidad del Viento vs. Salida de Potencia	32
23.	Histograma de Velocidad del Viento	32
24.	Gráfico de Series Temporales de Salida de Potencia y Consumo de Energía	33
25.	Rosa de los Vientos	33
26.	Análisis de variables climáticas y consumo de energía.	34
27.	Resultados del entrenamiento.	35
28.	Resultados del entrenamiento definitivo.	36
29.	Muestra de datos	38
30.	Acciones de ESS en caso 10 días	39

Indice de tablas

1.	Tabla de Frecuencias	7
2.	Tabla de Frecuencias	10
3.	Tabla de Frecuencias	13
4.	Estadísticas Descriptivas de las Variables	40
5.	Correlaciones entre las Variables	40

1. Introducción

La preocupación por el cambio climático y el aumento de la demanda de energía han impulsado el desarrollo de tecnologías energéticas más sostenibles [36]. En este escenario, las redes de distribución energética son esenciales para gestionar y suministrar electricidad de manera eficiente, desde los puntos de generación hasta los consumidores finales. La eficiencia de estas redes impacta no solo en la sostenibilidad ambiental, sino también en la estabilidad económica y la calidad de vida de las comunidades.

Uno de los principales retos en la gestión de estas redes es la integración de fuentes de energía renovables, como la solar y la eólica, que son variables e impredecibles [22]. La demanda de energía también varía significativamente, complicando la gestión eficiente de la carga y la minimización de pérdidas en la red. Estos desafíos requieren soluciones innovadoras capaces de adaptarse rápidamente a las condiciones cambiantes del entorno energético.

La IA se ha convertido en una herramienta crucial para abordar estos desafíos. Técnicas como el aprendizaje por refuerzo, los algoritmos evolutivos y las redes neuronales ofrecen nuevas formas de optimizar la operación de las redes de distribución energética, mejorando la eficiencia y reduciendo pérdidas. No obstante, implementar y evaluar estas técnicas en escenarios reales puede ser costoso y arriesgado. Por esta razón, la simulación se vuelve una herramienta vital para probar y optimizar estrategias antes de su implementación en el mundo real.

Los motores de videojuegos, como Unity y Unreal Engine, han evolucionado significativamente, proporcionando plataformas robustas para crear simulaciones complejas e interactivas [13]. Originalmente diseñadas para el desarrollo de juegos, estas herramientas ahora se utilizan en diversos campos, incluyendo la ingeniería, la medicina y la educación, debido a su capacidad para renderizar gráficos detallados y simular fenómenos físicos en tiempo real, así como permiten modelar de manera detallada y realista las redes de distribución energética y visualizar interactivamente los datos para mejorar la comprensión y el análisis [13].

La simulación de redes de distribución energética con motores de videojuegos ofrece varias ventajas. Primero, permite crear modelos detallados y realistas de la red, incluyendo subestaciones, transformadores, líneas de transmisión y fuentes de energía renovables. Estos modelos pueden interactuar en un entorno virtual que simula condiciones reales, permitiendo probar diferentes estrategias de gestión y optimización en un ambiente controlado y seguro [5][41].

Además, los motores de videojuegos facilitan la visualización interactiva, lo que mejora la comprensión y el análisis de los datos. Los usuarios pueden ajustar parámetros en tiempo real y observar los efectos inmediatos de estos cambios en la red, proporcionando una comprensión más profunda de cómo interactúan las diferentes variables. Esto es particularmente útil para la capacitación de operadores de redes y la educación de estudiantes en ingeniería energética [41] [14].

El uso de motores de videojuegos permite la creación de entornos 3D inmersivos.

Estos entornos pueden incluir capacidades de VR, lo que permite una percepción estereoscópica y una interacción natural con el entorno simulado. Esto aumenta la efectividad de las simulaciones al permitir a los usuarios experimentar y manipular el entorno virtual de una manera más realista y envolvente.

Las capacidades avanzadas de los motores de videojuegos también incluyen la simulación de dinámicas físicas como la iluminación, la gravedad y las colisiones de objetos. Estas características hacen que los motores de videojuegos sean herramientas adecuadas para una amplia variedad de aplicaciones en la visualización y simulación de redes energéticas y otros entornos complejos.

Estos beneficios hacen de los motores de videojuegos una opción poderosa y versátil para la simulación y optimización de redes de distribución energética, ofreciendo una plataforma robusta para la formación, la investigación y el desarrollo de nuevas estrategias de gestión energética.

El objetivo principal de esta investigación es desarrollar un modelo simulado de una red de distribución energética utilizando Unity, que permita la integración y evaluación de algoritmos de IA enfocados en la optimización de la distribución y el consumo de energía. Este modelo abordará los desafíos de gestión eficiente de la carga, minimización de pérdidas e integración de fuentes renovables en redes de distribución energética [12] [17].

Los algoritmos de inteligencia artificial, como el aprendizaje profundo y los métodos heurísticos, se utilizan para mejorar la eficiencia de la distribución energética. Estos algoritmos permiten optimizar la gestión de la red, reducir pérdidas y asegurar una distribución equilibrada de la carga [42].

Utilizar Unity como motor de simulación permite crear un entorno controlado donde se pueden probar diferentes estrategias de gestión sin los riesgos asociados a las pruebas en sistemas reales. Esto es crucial para asegurar que las estrategias desarrolladas sean efectivas y seguras antes de su implementación en el mundo real [4].

Este trabajo de investigación pretende contribuir al campo de la optimización de redes de distribución energética mediante la integración de técnicas de IA y el uso de motores de videojuegos para la simulación [37]. Los resultados buscan mejorar la eficiencia operativa de las redes energéticas y proporcionar una herramienta valiosa para la formación y capacitación en la gestión de redes energéticas. Al abordar los desafíos actuales en la gestión de redes de distribución energética y proponer soluciones innovadoras, este trabajo tiene el potencial de influir en futuras investigaciones y desarrollos en el campo de la energía sostenible [37], contribuyendo a un futuro más eficiente y ecológico.

2. Estado del Arte

2.1. Introducción

En el contexto del creciente énfasis global en las energías limpias y la gestión eficiente de la energía, este TFM propone desarrollar un modelo de simulación robusto que permita analizar y mejorar las redes de distribución energética mediante el uso de técnicas IA. La distribución de energía enfrenta desafíos constantes, tales como la gestión eficiente de la carga, la minimización de pérdidas y la implementación de fuentes renovables. Este apartado proporciona una base conceptual para la investigación, apoyándose en RSL y el mapping realizado.

La creciente adopción de energías limpias se debe en gran medida a los esfuerzos globales por mitigar el cambio climático y reducir la dependencia de los combustibles fósiles. La implementación de energías renovables como la solar y la eólica ha transformado el panorama energético, aunque también ha introducido desafíos técnicos, especialmente en la gestión de la variabilidad y la integración con las redes existentes. La inteligencia artificial ha emergido como una solución prometedora para abordar estos desafíos, ofreciendo herramientas avanzadas para optimizar la generación, distribución y consumo de energía mediante el análisis de grandes volúmenes de datos y la toma de decisiones en tiempo real [39][28].

2.2. Redes de Distribución Energética

Las redes de distribución energética son sistemas complejos diseñados para transportar electricidad desde los puntos de generación hasta los consumidores finales. Estos sistemas incluyen una variedad de componentes, como subestaciones, transformadores y líneas de transmisión y distribución. La eficiencia y fiabilidad de estas redes son cruciales para garantizar un suministro eléctrico continuo y de calidad [20][1].

La gestión de redes de distribución energética enfrenta múltiples desafíos, entre los cuales destacan la gestión eficiente de la carga, la minimización de pérdidas de energía y la integración de fuentes de energía renovables. La variabilidad en la producción de energía renovable y los cambios en los patrones de consumo añaden complejidad a la operación de estas redes. Para abordar estos desafíos, se están explorando diversas estrategias basadas en técnicas de inteligencia artificial.

2.3. Técnicas de Inteligencia Artificial Aplicadas a la Energía

La inteligencia artificial está transformando el sector energético, ofreciendo nuevas formas de optimizar la generación, distribución y consumo de energía. La IA puede analizar grandes volúmenes de datos y tomar decisiones en tiempo real, mejorando la eficiencia y reduciendo costos.

El aprendizaje por refuerzo es una técnica de IA que permite a los sistemas aprender mediante la interacción con su entorno. En el contexto de las redes energéticas, el aprendizaje por refuerzo se utiliza para optimizar la distribución de energía, ajustando dinámicamente la carga y minimizando las pérdidas. Estudios previos han demostrado que esta técnica puede mejorar significativamente la eficiencia operativa de las redes de distribución.

Los algoritmos evolutivos, que simulan el proceso de selección natural, son particularmente efectivos en entornos dinámicos y complejos, como las redes de distribución energética. Estos algoritmos permiten encontrar soluciones óptimas para la gestión de la carga y la integración de fuentes renovables [1][34]. Además del aprendizaje por refuerzo y los algoritmos evolutivos, otras técnicas de IA, como las redes neuronales y el aprendizaje automático, también juegan un papel importante en la optimización de redes energéticas, permitiendo predecir patrones de consumo y producción y ajustar la operación de la red en consecuencia.

2.4. Simulación de Redes Energéticas

La simulación es una herramienta crucial para el estudio y mejora de redes de distribución energética. Permite evaluar diferentes estrategias de gestión y optimización en un entorno controlado, sin riesgo para el sistema real [9].

Existen varias plataformas de simulación que se utilizan en el estudio de redes energéticas. Unity es una de las más destacadas debido a sus capacidades para desarrollar simulaciones interactivas tanto en 2D como en 3D. Unity permite crear modelos detallados y realistas de redes energéticas, facilitando el análisis y la optimización.

La simulación se ha utilizado en diversas investigaciones para evaluar el rendimiento de diferentes técnicas de gestión y optimización en redes energéticas. Estos estudios han demostrado que la simulación es una herramienta valiosa para probar nuevas estrategias y mejorar la eficiencia operativa de las redes de distribución.

2.5. Tecnologías y Herramientas Utilizadas

Unity es una plataforma de desarrollo ampliamente utilizada para juegos y simulaciones, destacada por su capacidad para crear entornos interactivos en 2D y 3D. Con el tiempo, Unity ha evolucionado más allá del desarrollo de videojuegos, convirtiéndose en una herramienta versátil en diversas industrias, incluida la simulación de redes energéticas [1].

Ofrece un motor gráfico robusto que permite crear visualizaciones detalladas y realistas, ideal para simulaciones interactivas que requieren precisión visual. Además, incluye un motor de física avanzado para simular fenómenos físicos complejos, como la transmisión de electricidad, el comportamiento de los dispositivos de almacenamiento de energía y la interacción entre componentes de la red.

Unity utiliza C# como lenguaje de scripting, ofreciendo flexibilidad y control sobre las simulaciones. Los desarrolladores pueden escribir scripts personalizados para definir el comportamiento de los componentes de la red, implementar algoritmos de IA y controlar la interacción del usuario. También cuenta con una amplia gama de herramientas y extensiones, incluyendo el Asset Store, que proporciona modelos 3D, scripts y otros recursos preconstruidos para acelerar el desarrollo.

Una de las principales ventajas de Unity es la capacidad de crear experiencias interactivas, permitiendo a los usuarios ajustar parámetros y observar los resultados en tiempo real. Unity soporta aplicaciones multiplataforma, ejecutándose en Windows, MacOS, iOS, Android y navegadores web.

Diversos estudios han utilizado Unity para simular redes eléctricas y evaluar estrategias de gestión. Por ejemplo, la simulación de microgrids con Unity permite analizar cómo diferentes configuraciones y estrategias de control afectan la estabilidad y eficiencia de la red. También se emplea en aplicaciones de formación y capacitación en el sector energético, proporcionando un entorno seguro para entrenar a los operadores de redes eléctricas.

3. Revisión sistemática de literatura

En esta sección, se presenta una revisión sistemática de la literatura enfocada en la optimización de redes de distribución energética mediante el uso de inteligencia artificial y la simulación con motores de videojuegos. Esta revisión tiene como objetivo identificar las tendencias actuales, los enfoques metodológicos, y las áreas de investigación más y menos exploradas en el campo. Adicionalmente, se ha realizado una búsqueda Ad Hoc para reforzar los hallazgos de la revisión sistemática, proporcionando un panorama más amplio y detallado sobre las soluciones innovadoras y prácticas implementadas recientemente.

Pregunta Principal:

1. ¿Cómo se han utilizado las técnicas de inteligencia artificial para optimizar las redes de distribución energética?

Preguntas Secundarias:

1. ¿Qué motores de videojuegos se han utilizado para simular redes de distribución energética?
2. ¿Cuáles son las principales tendencias en la aplicación de IA en la optimización de redes de distribución energética?
3. ¿Cuáles son las áreas de mayor y menor investigación en este campo?
4. ¿Qué metodologías se han implementado para la gestión eficiente de la carga en redes de distribución energética?

5. ¿Cómo se han minimizado las pérdidas en redes de distribución utilizando IA?
6. ¿Qué estrategias se han aplicado para la integración eficiente de fuentes de energía renovables en las redes de distribución?
7. ¿Qué técnicas de IA (aprendizaje por refuerzo, algoritmos evolutivos, redes neuronales, etc.) son más efectivas en la optimización de redes de distribución energética?
8. ¿Cómo se han comparado y evaluado diferentes algoritmos de IA en términos de eficiencia energética y reducción de pérdidas?
9. ¿Qué desafíos y limitaciones se han identificado en la aplicación de IA para la optimización de redes de distribución energética?
10. ¿Qué impacto tienen los escenarios de producción y consumo variable en la gestión y optimización de redes de distribución energética?

3.1. Metodología: Revisión Sistemática de Literatura

Se llevó a cabo una revisión sistemática de la literatura para identificar, evaluar y sintetizar la investigación existente sobre el uso de IA en la optimización de redes de distribución energética y el uso de motores de videojuegos para su simulación. La búsqueda se realizó en bases de datos académicas como Scopus, IEEE Xplore y Google Scholar.

Criterios de búsqueda

1. Uso de términos específicos como carga eficiente, minimización de pérdidas, integración de renovables, combinados con redes de distribución energética y IA.
2. Foco en estudios empíricos y de caso que proporcionen datos cuantitativos sobre la eficacia de las soluciones propuestas.

Estrategias de Búsqueda:

La búsqueda se realizó en bases de datos académicas como Scopus, IEEE Xplore y Google Scholar, utilizando la siguiente estrategia de búsqueda:

```
(energy distribution networks OR smart grids) AND (optimization OR efficiency)
AND (artificial intelligence OR machine learning OR reinforcement learning OR
evolutionary algorithms) AND (game engines OR Unity OR Unreal Engine OR
simulation OR interactive simulation OR digital twin)
```

Criterios de Inclusión

1. Artículos publicados entre 2020 y 2025.

2. Estudios que utilizan técnicas de IA para optimización de redes energéticas.
3. Publicaciones en inglés y español.

Criterios de Exclusión

1. Artículos de opinión, notas editoriales.
2. Estudios que no aplican directamente IA a la optimización de redes energéticas.

Resultados de la RSL Se identificaron 9562 artículos relevantes que fueron filtrados y categorizados en tres grupos principales: Optimización con IA, Uso de Motores de Videojuegos, y Energías Renovables. Los análisis bibliométricos y de co-ocurrencia de palabras clave revelaron las siguientes tendencias:

3.1.1. Optimización con IA:

Palabra Clave	Frecuencia
unsupervised learning	18
supervised learning	16
genetic algorithms	14
deep learning	12
neural learning	10
evolutionary algorithms	8
reinforcement learning	6
machine learning	4
artificial intelligence	2
optimization	0

Tabla 1: Tabla de Frecuencias




Figura 1: Frecuencias de palabras clave en IA

La figura 1 muestra la frecuencia de palabras clave relacionadas con el uso de IA en la optimización de redes de distribución energética. Las palabras clave Unsupervised Learning, Supervised Learning y Genetic Algorithms destacan por su alta frecuencia, indicando que estos temas son centrales en la literatura sobre la optimización de redes de distribución energética utilizando inteligencia artificial.

Interpretación de la Figura

1. **Unsupervised Learning:** Con la mayor frecuencia, esta palabra clave destaca la importancia del aprendizaje no supervisado en la identificación de patrones y la optimización en redes de distribución energética sin la necesidad de datos etiquetados.
2. **Supervised Learning:** La alta frecuencia de este término sugiere un enfoque significativo en el uso de modelos supervisados, que requieren datos etiquetados para entrenar algoritmos que puedan predecir y optimizar el comportamiento de las redes energéticas.
3. **Genetic Algorithms:** La frecuencia de esta palabra clave refleja el uso de algoritmos evolutivos inspirados en la biología para encontrar soluciones óptimas en problemas complejos de optimización.
4. **Deep Learning (Aprendizaje Profundo):** Esta palabra clave indica un interés considerable en el uso de redes neuronales profundas para modelar y optimizar redes de distribución energética, aprovechando su capacidad para manejar grandes volúmenes de datos y complejidades.
5. **Neural Networks:** La frecuencia de este término sugiere que las redes neuronales son una herramienta central en la investigación de la optimización energética, proporcionando capacidades avanzadas de modelado y predicción.
6. **Evolutionary Algorithms:** Estos algoritmos son importantes por su capacidad para adaptarse y evolucionar, encontrando soluciones óptimas en entornos dinámicos y cambiantes.
7. **Reinforcement Learning:** La inclusión de este término refleja su relevancia en la optimización en tiempo real y la toma de decisiones basadas en la retroalimentación continua del sistema.
8. **Machine Learning:** Este término general engloba diversas técnicas de IA que son cruciales para la optimización y gestión eficiente de redes de distribución energética.
9. **IA:** La frecuencia de este término destaca la importancia general de las técnicas de IA en el campo de la optimización energética.
10. **Optimization:** Aunque con menor frecuencia relativa, este término es fundamental, indicando el objetivo último de todas estas técnicas: mejorar la eficiencia y el rendimiento de las redes de distribución energética.




Figura 2: Red de coocurrencia IA

La Figura 2 muestra la red de coocurrencia de palabras clave en la literatura sobre la optimización de redes de distribución energética utilizando IA. En esta red, los nodos representan palabras clave y los bordes representan la coocurrencia de estas palabras clave en los documentos.

3.1.2. Uso de motores de videojuegos:

Palabra Clave	Frecuencia
gaming technology	27
3d simulation	24
augmented reality	21
virtual reality	18
digital twin	15
interactive simulation	12
simulation	9
unreal engine	6
unity	3
game engines	0

Tabla 2: Tabla de Frecuencias




Figura 3: Frecuencia de palabras clave Motores Gráficos

La Figura 3 muestra la frecuencia de palabras clave relacionadas con el uso de motores gráficos. Las palabras clave Gaming Technology, 3D Simulation y Augmented Reality destacan por su alta frecuencia, sugiriendo que las tecnologías de juegos y la simulación 3D son temas dominantes en esta área de estudio. Además, términos como Virtual Reality y Digital Twin también son prominentes, indicando un interés significativo en aplicaciones de realidad virtual y gemelos digitales.

Interpretación de la Figura

1. Gaming Technology: Con la mayor frecuencia, esta palabra clave destaca la importancia de las tecnologías de juegos en la simulación y modelado de sistemas complejos.
2. 3D Simulation: La alta frecuencia de esta palabra clave sugiere un enfoque en la creación de entornos tridimensionales detallados para la visualización y análisis de estrategias de gestión de redes energéticas.
3. Augmented Reality (RA): La frecuencia de este término refleja el creciente interés en utilizar la realidad aumentada para mejorar la interacción y comprensión de las simulaciones.
4. Virtual Reality (VR): Similar a la realidad aumentada, la realidad virtual se utiliza ampliamente para crear entornos inmersivos que pueden mejorar la capacitación y la experimentación.
5. Digital Twin: La frecuencia de esta palabra clave indica un interés significativo en replicar sistemas físicos en un entorno digital para facilitar el monitoreo y la optimización en tiempo real.
6. Interactive Simulation: Esta palabra clave sugiere que la interactividad es un componente crucial en las simulaciones, permitiendo a los usuarios probar diferentes escenarios y estrategias en tiempo real.

La literatura actual parece estar centrada en la aplicación de tecnologías avanzadas de juegos y simulación para mejorar la visualización, análisis e interactividad en la gestión de redes energéticas. Esto incluye un enfoque significativo en la realidad aumentada y virtual, así como en el desarrollo de gemelos digitales para replicar y optimizar sistemas físicos en un entorno digital.

La Figura 4 de términos relacionados con el uso de motores gráficos y simulaciones en la literatura sobre redes de distribución energética. En esta red, los nodos representan términos clave y los bordes representan la coocurrencia de estos términos en los documentos.

Interpretación de la Figura:

1. **Simulation:** Este nodo es uno de los vértices del triángulo, conectado a términos como Unity, Unreal Engine y Digital Twin. Esto indica la relevancia de la simulación en la creación de entornos virtuales para el análisis y la optimización de redes energéticas.




Figura 4: Red de concurrencia de los Motores Gráficos

2. **Unity y Unreal Engine:** Estos términos muestran una fuerte coocurrencia con simulation, sugiriendo que estas plataformas de desarrollo de juegos son ampliamente utilizadas para crear simulaciones interactivas y visualmente ricas en el campo de la distribución energética.
3. **Digital Twin:** La conexión con simulation refleja el uso de gemelos digitales para replicar sistemas físicos en un entorno virtual, permitiendo una mejor monitorización y optimización.

La red de coocurrencia muestra que la simulación es una técnica central en la investigación actual sobre redes de distribución energética, con un fuerte enfoque en el uso de plataformas como Unity y Unreal Engine para crear simulaciones avanzadas. Los gemelos digitales también juegan un papel crucial al permitir la replicación y optimización de sistemas reales en un entorno virtual.

3.1.3. Energías Renovables

Palabra Clave	Frecuencia
energy efficiency	36
energy storage	32
geothermal energy	28
hydropower	24
green energy	20
sustainable energy	16
battery management systems	12
wind power	8
solar energy	4
renewable energy	0

Tabla 3: Tabla de Frecuencias




Figura 5: Frecuencia de palabras claves en Energías Renovables

La Figura 5 muestra las palabras más comunes en la literatura sobre energías renovables. Las palabras clave *energy efficiency*, *energy storage* y *geothermal energy* son las más frecuentes, reflejando un fuerte enfoque en la eficiencia energética y el almacenamiento de energía dentro de la literatura. Otras palabras clave importantes incluyen *hydropower*, *green energy* y *sustainable energy*, que también son prominentes en la investigación actual.

Por otro lado, palabras clave como *renewable energy*, *solar energy* y *wind power* tienen una menor frecuencia en comparación, aunque siguen siendo áreas esenciales de investigación. Esto sugiere que, si bien la energía solar y eólica son importantes, la investigación actual podría estar priorizando temas de eficiencia energética y almacenamiento, que son cruciales para la integración efectiva de fuentes de energía renovables en las redes de distribución.

Interpretación de la Figura

1. ***Energy Efficiency* (Eficiencia Energética):** Con la mayor frecuencia, esta palabra clave destaca la importancia de mejorar la eficiencia en el uso de energía renovable para maximizar los beneficios y reducir desperdicios.
2. ***Energy Storage* (Almacenamiento de Energía):** También con alta frecuencia, el almacenamiento de energía es crucial para gestionar la intermitencia de las fuentes renovables y asegurar un suministro constante.
3. ***Geothermal Energy* (Energía Geotérmica):** La frecuencia de esta palabra clave indica un interés significativo en esta fuente de energía renovable, que proporciona una alternativa estable y sostenible.
4. ***Hydropower* (Energía Hidroeléctrica):** La energía hidroeléctrica sigue siendo un área importante de investigación debido a su capacidad de generar grandes cantidades de energía limpia.
5. **Green Energy (Energía Verde) y Sustainable Energy (*Energía Sostenible*):** Estas palabras clave reflejan un enfoque en la sostenibilidad y el desarrollo de fuentes de energía ambientalmente amigables.

La literatura actual parece estar centrada en mejorar la eficiencia energética y las soluciones de almacenamiento, al mismo tiempo que explora diversas fuentes de energía renovable como la geotérmica y la hidroeléctrica. La menor frecuencia de términos como *solar energy* y *wind power* no indica una falta de importancia, sino más bien una posible consolidación de conocimiento previo y un enfoque en resolver problemas operacionales críticos como la eficiencia y el almacenamiento.




Figura 6: Red de coocurrencia en terminos relacionados con la energías renovables

La figura 6 muestra los términos relacionados con las energías renovables. En esta red, *renewable energy* es el nodo más central, con fuertes conexiones a *solar energy*, *wind power* y *battery management systems*. Esto sugiere un enfoque integrado en estas áreas dentro de la investigación de energías renovables.

1. ***Renewable Energy* (Energía Renovable)**: Es el nodo central, mostrando su importancia como tema principal en la literatura sobre energías renovables.
2. ***Solar Energy* (Energía Solar) y *Wind Power* (Energía Eólica)**: Estas conexiones indican un enfoque significativo en las energías solar y eólica como componentes cruciales de la energía renovable.
3. **Energy Storage y Battery Management Systems**: La coocurrencia de estos términos con *renewable energy* destaca la importancia del almacenamiento de energía y la gestión eficiente de las baterías en el contexto de la energía renovable.
4. ***Green Energy* y *Energy Efficiency***: Estos términos también están conectados con *renewable energy*, reflejando un interés en la sostenibilidad y la eficiencia dentro de las soluciones energéticas renovables.

La red de coocurrencia muestra que la energía renovable es un tema central con conexiones clave a la energía solar, eólica y los sistemas de gestión de baterías, lo que sugiere un enfoque integrado en estas áreas dentro de la investigación de energías renovables.

3.2. Metodología: Búsqueda Ad Hoc

Para reforzar la revisión sistemática, se realizó una búsqueda Ad Hoc centrada en la gestión eficiente de las redes de distribución energética, enfrentando desafíos como la gestión eficaz de la carga, la minimización de pérdidas y la integración eficiente de fuentes de energía renovables. Esta búsqueda adicional se centró en identificar investigaciones recientes con soluciones innovadoras y enfoques prácticos que se pudieran amoldar a nuestra investigación.

3.2.1. Hallazgos de la Búsqueda Ad Hoc

La literatura revisada muestra un enfoque significativo en el uso de técnicas de inteligencia artificial como el aprendizaje por refuerzo y los algoritmos evolutivos en la optimización energética. Estas técnicas han demostrado ser efectivas para mejorar la eficiencia operativa de las redes de distribución, ajustando dinámicamente la carga y minimizando las pérdidas.

El aprendizaje por refuerzo se ha utilizado ampliamente para la gestión en tiempo real de la carga y la distribución de energía, mostrando mejoras considerables en la eficiencia energética y la reducción de costos operativos. Por otro lado, los algoritmos evolutivos se aplican para encontrar soluciones óptimas en entornos dinámicos, siendo exitosos en la integración de fuentes de energía renovables y la gestión de la variabilidad en la producción y consumo de energía.

En cuanto al uso de motores de videojuegos para la simulación de redes energéticas, se observa un creciente interés en plataformas como *Unity* y *Unreal Engine*. Estos motores permiten la creación de entornos virtuales detallados y realistas que facilitan la visualización y análisis de diferentes estrategias de gestión. *Unity* es popular por su capacidad para desarrollar simulaciones interactivas en 2D y 3D, siendo ampliamente utilizado en estudios para modelar y optimizar redes energéticas. Por su parte, *Unreal Engine* ofrece gráficos avanzados y capacidades de simulación robustas, utilizado en la formación y capacitación en gestión de redes energéticas.

3.2.2. Tendencias Principales Identificadas

Optimización Energética con IA

- **Aprendizaje por Refuerzo:** Esta técnica se ha utilizado extensamente para la gestión en tiempo real de la carga y la distribución de energía. Los estudios muestran mejoras considerables en la eficiencia energética y la reducción de costos operativos al ajustar dinámicamente la carga y minimizar las pérdidas.
- **Algoritmos Evolutivos:** Aplicados para encontrar soluciones óptimas en entornos dinámicos, estos algoritmos han demostrado éxito en la integración de fuentes de energía renovables y la gestión de la variabilidad en la producción y consumo de energía.

- **Algoritmos Híbridos:** La combinación de múltiples técnicas de IA para mejorar la robustez y eficiencia de las soluciones de optimización es una tendencia creciente

Simulación de Redes Energéticas con Motores de Videojuegos

- **Unity y Unreal Engine:** Estos motores permiten la creación de entornos virtuales detallados y realistas que facilitan la visualización y análisis de diferentes estrategias de gestión. Unity es conocido por su capacidad para desarrollar simulaciones interactivas en 2D y 3D, mientras que Unreal Engine ofrece gráficos avanzados y capacidades de simulación robustas.
- **Simulaciones en Tiempo Real:** Implementación de simulaciones en tiempo real para evaluar el impacto de diferentes estrategias de gestión en la red energética, permitiendo una mejor adaptación y respuesta a las condiciones cambiantes.

Integración de Múltiples Fuentes Renovables

- **Energía Solar y Eólica:** Estudio de estrategias para integrar eficientemente estas fuentes de energía en las redes de distribución. La gestión eficiente de la variabilidad en la producción y consumo de energía es un enfoque clave.
- **Sistemas de Gestión de Baterías:** La coocurrencia de términos como *energy storage* y *battery management systems* con *renewable energy* destaca la importancia del almacenamiento de energía y la gestión eficiente de las baterías.

3.2.3. Artículo de Referencia

El artículo *Potentials of game engines for wind power digital twin development: an investigation of the Unreal Engine* [23] explora el uso de motores de videojuegos, específicamente *Unreal Engine*, para el desarrollo de gemelos digitales de energía eólica. Los hallazgos principales incluyen:

- **Gemelos Digitales:** Los motores de videojuegos son viables para construir gemelos digitales completos con interfaces gráficas realistas. Unreal Engine 5 proporciona las capacidades necesarias para desarrollar representaciones digitales detalladas de turbinas eólicas y su entorno. Según Sørensen et al., los motores de videojuegos son viables para construir gemelos digitales completos donde se requiere una interfaz gráfica realista. Unreal Engine 5 proporciona las herramientas para modelar el paisaje, el agua circundante y la iluminación [5].
- **Caso de Estudio:** Se utilizó un estudio de caso con dos tipos de turbinas eólicas y datos históricos de viento para evaluar la producción de energía bajo diferentes condiciones. Los resultados muestran que los motores de videojuegos

pueden replicar con precisión las condiciones del mundo real y proporcionar una herramienta eficaz para el análisis y optimización de la producción de energía eólica. El estudio de Sørensen et al. indicó que el gemelo digital incluye el entorno con datos históricos del viento y la representación visual de la turbina eólica con un modelo de producción de energía eólica y la producción estimada en las condiciones de viento dadas del área. Además, [32]. destacaron que los motores de videojuegos modernos ofrecen una gran plataforma para crear aplicaciones de gemelos digitales urbanos, aunque se deben superar algunos problemas y limitaciones antes de que el uso de datos geoespaciales en motores de videojuegos sea factible a gran escala [32].

3.2.4. Conclusión

La búsqueda Ad Hoc y el análisis de la bibliografía han identificado tendencias clave en la optimización energética mediante técnicas de IA y el uso de motores de videojuegos para la simulación de redes energéticas. La integración de múltiples fuentes renovables y el desarrollo de algoritmos híbridos y simulaciones en tiempo real son áreas de interés prominente. Estos hallazgos subrayan la importancia de continuar explorando y desarrollando técnicas avanzadas para mejorar la eficiencia y sostenibilidad de las redes de distribución energética.

La inteligencia artificial se utiliza comúnmente para construir gemelos digitales y se aplica para predecir, detectar, tomar decisiones, planificar y diagnosticar. Los métodos de IA más comunes incluyen el aprendizaje automático, las redes neuronales y los algoritmos genéticos [11].

Los motores de videojuegos son viables para construir gemelos digitales completos con interfaces gráficas realistas. Unreal Engine 5 proporciona las herramientas necesarias para modelar el paisaje, el agua circundante y la iluminación [23]. Los motores de videojuegos modernos ofrecen una gran plataforma para crear aplicaciones de gemelos digitales urbanos; sin embargo, algunos problemas y limitaciones deben superarse antes de que el uso de datos geoespaciales en motores de videojuegos sea factible a gran escala [32].

Los modelos de simulación pueden estar interconectados para proporcionar sus resultados a programas externos y establecer bucles de retroalimentación. La interconexión de modelos de simulación también se refiere a la simulación sincronizada o la co-simulación, donde los modelos de simulación heterogéneos se interconectan a través de interfaces funcionales de simulación [20].

3.3. Discusión

Los resultados indican una fuerte tendencia en la aplicación de técnicas de IA, como el aprendizaje por refuerzo y los algoritmos evolutivos, para la optimización de redes de distribución energética. El uso de motores de videojuegos, particularmente Unity, se ha destacado como una herramienta efectiva para la simulación y prueba

de estos algoritmos en entornos interactivos y visualmente representativos [7] [44].

Las técnicas de IA están demostrando ser efectivas en la gestión y optimización de redes energéticas, ofreciendo soluciones innovadoras para los desafíos actuales. Los motores de videojuegos, al proporcionar un entorno de simulación realista, permiten a los investigadores probar y validar sus modelos de manera más eficiente [24] [15].

Las limitaciones de esta investigación incluyen la dependencia de la disponibilidad de datos públicos y la necesidad de herramientas de simulación avanzadas. Las oportunidades futuras incluyen la exploración de nuevas técnicas de IA, como el aprendizaje profundo, y la expansión del uso de motores de videojuegos en otros dominios energéticos [43].

3.4. Conclusión

Esta investigación ha demostrado la efectividad de las técnicas de IA en la optimización de redes de distribución energética y el potencial de los motores de videojuegos como herramientas de simulación. Los principales hallazgos incluyen la identificación de tendencias clave y vacíos en la investigación actual. Se recomienda investigar más a fondo el uso de técnicas de aprendizaje profundo y otros algoritmos avanzados de IA en la optimización de redes energéticas. Además, es importante explorar la integración de diferentes motores de videojuegos y su impacto en la precisión y eficiencia de las simulaciones [18].

4. Caso de estudio

En este caso de estudio se detalla el desarrollo de un entorno de simulación en Unity para la gestión de redes de distribución energética. El proceso incluye la creación de modelos 3D de aerogeneradores, el diseño de clases abstractas y la implementación de componentes necesarios para su funcionamiento. Este entorno permite una visualización interactiva y la optimización de estrategias de gestión mediante el uso de datos reales y técnicas de inteligencia artificial [21].

4.1. Desarrollo del Sandbox

El primer paso del proyecto fue la generación de un modelo 3D detallado de un aerogenerador. Utilizando las capacidades gráficas de Unity, se creó un modelo que representa fielmente la estructura y el funcionamiento de un aerogenerador. Este modelo sirve como base visual para la simulación y proporciona una referencia precisa para el análisis de su comportamiento.

Para permitir la creación de diferentes tipos de aerogeneradores, se desarrolló una clase abstracta llamada Turbina. Esta clase define las propiedades y métodos esenciales que cualquier aerogenerador debe tener, actuando como una plantilla para



Figura 7: Sandbox de unity

la creación de instancias específicas de aerogeneradores. Las clases derivadas pueden extender esta base, permitiendo la implementación de características particulares de cada tipo de aerogenerador.

Se añadieron todos los componentes necesarios para el funcionamiento del aerogenerador mediante scripts que controlan su comportamiento. Estos scripts incluyen la programación de la curva de potencia del aerogenerador, que describe su rendimiento en función de la velocidad del viento. La curva de potencia es crucial para simular con precisión la generación de energía bajo diferentes condiciones. El aerogenerador seleccionado es el “Enercon E126/7580” [35] con una capacidad de 7,58 MW pico para cubrir toda la demanda durante la simulación.





Figura 8: Modelo aerogenerador

Se diseñó una interfaz para clasificar todos los elementos que actúan como fuentes de energía dentro del sistema. Esta interfaz asegura que cualquier nueva fuente de energía pueda integrarse de manera uniforme al entorno de simulación, siguiendo una estructura estandarizada.

Se creó un objeto mánager para el microgrid, responsable de controlar todas las fuentes de energía, el consumo y el almacenamiento dentro del sistema. Este mánager coordina el flujo de energía, optimizando la distribución y asegurando que la demanda sea satisfecha de manera eficiente.

Se implementó una interfaz visual para monitorizar la energía generada en diferentes escenarios. Esta herramienta proporciona información en tiempo real sobre la

Figura 9: Inspector de configuración del *microgrid Manager*

producción y el consumo de energía, facilitando el análisis y la toma de decisiones informadas. Para aumentar la precisión de la simulación, se integró un dataset con datos reales del aerogenerador. Estos datos permiten ajustar y validar la curva de potencia y el comportamiento general del aerogenerador en la simulación, garantizando que los resultados sean representativos de condiciones reales.

Figura 10: Inspector de configuración del *Wind Manager*

Se desarrolló una clase abstracta denominada *Consumer*, que facilita la creación de diferentes tipos de consumidores de energía. Esta clase proporciona una base común para todos los consumidores, permitiendo su integración y gestión dentro del microgrid de manera uniforme.

Se añadió un *mánager* para regular el ciclo día-noche, ajustando el consumo de energía según la hora del día. Este componente es esencial para simular patrones de consumo realistas y optimizar el uso de fuentes de energía renovables.

Para crear un entorno de simulación realista basado en la isla de El Hierro, seguí un proceso meticuloso que comenzó con la obtención del *heightmap* de la isla. Utilicé el sitio web *Cities: Skylines online heightmap generator* [30] para obtener los datos precisos de posición y altura de la isla. La imagen generada se importó a *Unity* usando **ProBuilder**, un paquete especializado que permite la creación y edición de geometría dentro del entorno de desarrollo.

ProBuilder facilita la importación y manipulación de *heightmaps*, lo que permitió generar un terreno tridimensional detallado que refleja fielmente la topografía de El Hierro. Las imágenes adjuntas demuestran el éxito de este proceso, mostrando claramente la topografía y las condiciones específicas de la isla.

Este método tiene varios beneficios. En primer lugar, proporciona autenticidad, ya que la simulación se desarrolla en un entorno geográficamente preciso, mejorando la inmersión y la validez de los escenarios simulados. Además, la inclusión de detalles topográficos permite simular condiciones más realistas, lo que es crucial para estudios ambientales, juegos y simulaciones científicas [6] [26]. En conjunto, este enfoque asegura que el entorno de simulación no solo sea visualmente fiel, sino también

funcionalmente relevante para diversas aplicaciones.



Figura 11: *Heighthmap* de la isla




Figura 12: Modelo 3D de la isla

Se crearon modelos 3D simples para representar los consumidores y las baterías en la simulación.




Figura 13: Modelos 3D simples de consumidores

Estos modelos visualizan la distribución y el almacenamiento de energía, proporcionando una representación clara y comprensible del sistema. Los tipos de consumidores incluidos en la simulación son variados y representan diferentes perfiles de demanda de energía:

- **Hogares:** Se han incluido varios modelos de hogares que representan consumidores residenciales. Estos hogares tienen perfiles de consumo de energía que varían según la hora del día y la temporada.
- **Infraestructura de Transporte de Agua:** También se ha modelado la infraestructura de transporte de agua, que actúa como un consumidor industrial

de energía. Este tipo de infraestructura tiene un consumo de energía más constante pero también más significativo en comparación con los hogares.

- **Edificios Comerciales:** Se han añadido modelos de edificios comerciales con patrones de consumo de energía que varían durante las horas de funcionamiento y los fines de semana.
- **Fábricas:** Representan consumidores industriales con altas demandas de energía y patrones de consumo específicos relacionados con los ciclos de producción.

Se han implementado diferentes sistemas de almacenamiento de energía para gestionar la oferta y la demanda:

- **Baterías de Ion-Litio:** La simulación incluye el almacenamiento de energía mediante baterías de ion-litio, que se utilizan para balancear la producción y el consumo. Estas baterías son esenciales para la estabilidad de la red, permitiendo almacenar excedentes de energía y suministrar energía durante los picos de demanda [2].
- **Baterías de Flujo:** Se ha modelado el uso de baterías de flujo para aplicaciones de almacenamiento de energía a gran escala. Estas baterías son adecuadas para almacenar grandes cantidades de energía y son utilizadas para mejorar la capacidad de almacenamiento de la red [2].

Estos modelos no solo ayudan a visualizar la distribución y el almacenamiento de energía, sino que también permiten analizar cómo diferentes tipos de consumidores afectan la gestión y la eficiencia de la red de distribución energética en la simulación y, además, la implementación de estos sistemas de almacenamiento permite una gestión más eficiente de la energía generada y consumida, optimizando el balance energético dentro del microgrid simulado.

Finalmente, se implementaron tres aerogeneradores para simular una generación de energía realista. Esta configuración permite evaluar el rendimiento y la eficiencia del sistema en condiciones operativas similares a las del mundo real.




Figura 14: Diagrama esquemático de los diferentes tipos de consumidores y su integración en la red de distribución energética [10]

4.2. Datos Seleccionados

Se ha utilizado el dataset [31] *Wind Turbine Scada Dataset* que recoge los datos de un aerogenerador tales como la generación real, la estimada, la velocidad del viento y la dirección en intervalos de 10 minutos. Estos datos se integran en el sandbox para simular de manera precisa la producción de energía eólica.

Estos datos se integran en el sandbox para simular de manera precisa la producción de energía eólica.

Después de la simulación, se genera un dataset que permite observar la curva teórica de potencia del aerogenerador. Este dataset incluye la salida de energía, las RPM y la velocidad del viento, proporcionando una serie temporal que muestra la evolución de la generación de energía de la microrred completa. Este análisis temporal es fundamental para entender el comportamiento dinámico del sistema y optimizar su funcionamiento.

En esta figura se muestra la relación entre la velocidad del viento y la salida de potencia del aerogenerador, así como las RPM. La curva teórica de potencia ilustra cómo aumenta la generación de energía con la velocidad del viento hasta alcanzar un punto de saturación, después del cual la potencia se estabiliza o disminuye ligeramente debido a las limitaciones del aerogenerador.

Este gráfico presenta la generación de energía y las RPM del aerogenerador a lo largo del tiempo, utilizando datos del dataset de simulación. La variabilidad en la generación y las RPM reflejan las fluctuaciones en la velocidad del viento y cómo estas afectan el rendimiento del aerogenerador en una serie temporal.

La Figura 18: Comparativa de la potencia activa y la potencia ideal de la generación compara la potencia activa generada por el aerogenerador con la potencia ideal esperada según la curva teórica. Este análisis permite identificar las discrepancias




Figura 15: Rosa de los vientos

entre la generación real y la ideal, proporcionando información valiosa para ajustar y optimizar el rendimiento del sistema de generación de energía eólica.

Estas figuras son esenciales para comprender cómo las condiciones del viento y las características del aerogenerador afectan la producción de energía, y para evaluar la precisión y eficiencia del modelo de simulación implementado.

4.3. Implementación de Algoritmos de IA

El caso de estudio involucra la simulación de una red eléctrica utilizando ML-Agents. En esta simulación, los algoritmos de IA fueron capaces de ajustar la producción de energía en tiempo real, respondiendo a cambios en la demanda con una precisión que superó a los métodos tradicionales. Esto resultó en una reducción significativa del desperdicio energético y una mejora notable en la eficiencia operativa de la red.

La Figura 17: Interfaz Unity MLAgents muestra la interfaz de línea de comandos utilizada para iniciar el entrenamiento del agente en Unity ML-Agents [29]. A




Figura 16: Curva Teorica e Ideal del aerogenerador




Figura 17: Salida de potencia y velocidad de giro frente a la velocidad de viento

continuación, se detalla el proceso de configuración y entrenamiento:

```
mlagents-learn config.yaml --run-id=EnergyDistributionRun
```

El sistema escucha en el puerto 5004 y el entrenamiento se inicia presionando el botón de Play en el editor de Unity. Una vez se presiona el botón de Play en el Unity Editor, se desencadenan varias etapas en el proceso de entrenamiento del agente de IA:

1. Inicialización del Entorno: Unity comienza a ejecutar el entorno de simulación configurado. El agente de IA, junto con el entorno, es inicializado con los parámetros especificados en el archivo config.yaml.
2. Recopilación de Datos: El agente empieza a interactuar con el entorno. A medida que ejecuta acciones, recopila datos sobre el estado del sistema, como el consumo de energía, la generación de energía y otros factores relevantes.
3. Ciclo de Aprendizaje:




Figura 18: Comparativa de la potencia activa y la potencia ideal de la generación

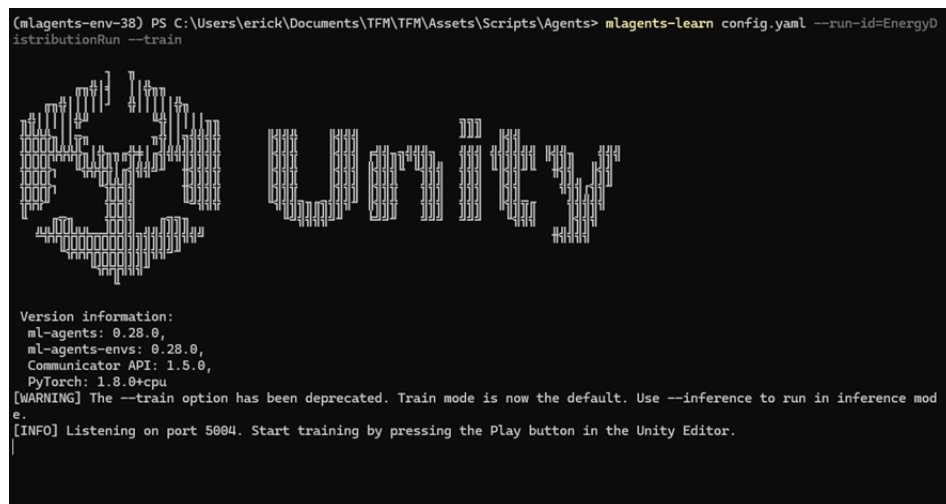


Figura 19: Interfaz Unity MLAgents

- a) Exploración y Explotación: El agente alterna entre explorar nuevas estrategias y explotar las estrategias conocidas que han demostrado ser efectivas [33].
 - b) Actualización del Modelo: Utilizando algoritmos de aprendizaje por refuerzo, el agente ajusta sus políticas de acción basándose en las recompensas obtenidas por sus acciones. La política es la estrategia que define qué acciones tomar en cada estado del entorno.
 - c) Recompensa y Penalización: El agente recibe recompensas positivas por acciones que mejoran la eficiencia energética y reducen pérdidas, y recompensas negativas (o penalizaciones) por acciones que no son óptimas.
4. Entrenamiento Iterativo: El proceso de interacción y aprendizaje se repite durante múltiples episodios de simulación. Con cada iteración, el agente mejora su capacidad para tomar decisiones eficientes. Este enfoque iterativo permite que el agente aprenda y ajuste sus estrategias basándose en la retroalimentación.

ción constante del entorno. Esta capacidad de aprendizaje continuo es esencial para adaptarse a condiciones cambiantes y optimizar el rendimiento a lo largo del tiempo [3] [16].

5. Evaluación del Desempeño: Durante el entrenamiento, se monitorizan métricas clave para evaluar el desempeño del agente, como la eficiencia energética y la reducción de costos [8] [19].
6. Ajuste de Hiperparámetros: Basado en los resultados de evaluación, los hiperparámetros del modelo pueden ajustarse para optimizar el desempeño del agente. Esto puede incluir parámetros como la tasa de aprendizaje, el factor de descuento, entre otros.
7. Convergencia: El proceso de entrenamiento continúa hasta que el agente alcanza un nivel de desempeño satisfactorio, definido por criterios de convergencia preestablecidos.
8. Modo de Inferencia: Una vez que el agente ha sido entrenado y validado, se puede cambiar al modo de inferencia, donde utiliza el conocimiento adquirido para tomar decisiones en tiempo real sin seguir aprendiendo.

4.3.1. Aprendizaje por Refuerzo

Se ha desarrollado un agente que aprende a gestionar la distribución de energía en tiempo real, optimizando la eficiencia energética y minimizando las pérdidas. Este agente utiliza algoritmos avanzados de aprendizaje por refuerzo para tomar decisiones informadas y adaptativas en un entorno dinámico y complejo [40].




Figura 20: Diagrama Ilustrativo del aprendizaje por refuerzo [27]

Características principales del agente:

- Adaptabilidad: El agente ajusta sus estrategias de distribución basándose en los datos en tiempo real y en las condiciones cambiantes del sistema [38].
- Optimización: Utiliza técnicas de optimización para asegurar que la distribución de energía sea lo más eficiente posible, reduciendo al mínimo las pérdidas [38].
- Aprendizaje continuo: A medida que opera, el agente sigue aprendiendo y mejorando sus decisiones, volviéndose más efectivo con el tiempo [38].
- Datos en tiempo real: Emplea datos actuales sobre el consumo de energía, la generación y otros factores relevantes para tomar decisiones informadas [38].
- Beneficios del agente de aprendizaje por refuerzo:
 - Reducción de costos: Al optimizar la distribución de energía, se pueden reducir los costos operativos y de infraestructura [38] [45].
 - Mejora de la eficiencia: Una distribución más eficiente implica un mejor uso de los recursos energéticos disponibles [38] [45].
 - Sostenibilidad: Al minimizar las pérdidas de energía, se contribuye a una gestión más sostenible y ecológica del sistema energético.




Figura 21: Diagrama de flujo del proceso de implementación de algoritmos de IA en la simulación de la red energética [25].

4.4. Evaluación del Modelo

4.4.1. Proceso de Evaluación

El modelo propuesto ha sido sometido a una evaluación bajo distintos escenarios de producción y consumo energético. En estos escenarios, se han medido varias métricas clave para determinar la eficiencia del sistema, incluyendo la eficiencia energética, la reducción de pérdidas y la adaptabilidad del sistema frente a fluctuaciones en la demanda y la oferta de energía.

4.4.2. *Dataset* de Resultados y Análisis

Para el análisis de los resultados obtenidos de las simulaciones, se ha construido un *dataset* detallado que captura todos los datos relevantes generados durante los experimentos. Este *dataset* se ha analizado utilizando *Python* y bibliotecas populares como *Pandas* y *Matplotlib*. Estas herramientas han sido cruciales para la manipulación, visualización y análisis de datos, proporcionando información visual clara sobre cómo se comporta su modelo en diferentes condiciones. A continuación, se presentan algunas de las visualizaciones obtenidas del análisis de los datos de simulación:




Figura 22: Diagrama de Dispersión de Velocidad del Viento vs. Salida de Potencia

La Figura 22: Diagrama de Dispersión de Velocidad del Viento vs. Salida de Potencia muestra cómo la salida de potencia varía en función de la velocidad del viento. La gráfica revela una curva característica de la relación entre la velocidad del viento y la potencia generada, con un incremento rápido hasta alcanzar un punto de saturación.




Figura 23: Histograma de Velocidad del Viento

La Figura 23: Histograma de Velocidad del Viento ilustra la distribución de las velocidades del viento registradas durante el periodo de simulación. Se observa una distribución uniforme en la mayoría de los rangos de velocidad, con picos notables en los extremos.

La Figura 24: Gráfico de Series Temporales de Salida de Potencia y Consumo de Energía muestra la evolución temporal tanto de la salida de potencia como del consumo de energía. Se puede observar la estacionalidad y las tendencias a lo largo del tiempo.




Figura 24: Gráfico de Series Temporales de Salida de Potencia y Consumo de Energía






Figura 25: Rosa de los Vientos

La Figura 25 proporciona información sobre la dirección y velocidad del viento, mostrando la frecuencia de diferentes velocidades del viento provenientes de diversas direcciones.



(a) Gráfico Multivariable de Velocidad del Viento, Dirección del Viento y Salida de Potencia



(b) Diagrama de Caja de Consumo de Energía por Mes

Figura 26: Análisis de variables climáticas y consumo de energía.

La Figura 26a representa la relación entre varias variables clave, proporcionando una visión comprensiva de cómo interactúan la velocidad y dirección del viento con la salida de potencia.

La Figura 26b muestra la distribución del consumo de energía mensual, destacando la mediana, cuartiles y valores atípicos para cada mes del año.

4.4.3. Métricas de Evaluación


La eficiencia energética fue uno de los indicadores clave evaluados. Esta métrica mide cuánta energía producida es realmente utilizada por los usuarios finales y no se pierde en el proceso de transmisión y distribución. La evaluación de la eficiencia energética es importante para determinar la viabilidad del modelo en aplicaciones del mundo real, donde maximizar el consumo de energía es importante desde la perspectiva económica y ambiental.

Otra cifra clave importante es la reducción de pérdidas. Esta evaluación se centra en la capacidad del modelo para minimizar las pérdidas de energía que inevitablemente ocurren durante la transmisión y distribución de electricidad. Los sistemas que pueden reducir significativamente estas pérdidas contribuyen a un uso más eficiente de los recursos energéticos disponibles, lo cual es crucial para la sostenibilidad y la rentabilidad a largo plazo.

Finalmente, se evaluó la adaptabilidad del sistema en términos de su capacidad para responder a cambios en la oferta y demanda de energía. Esta métrica es particularmente importante para sistemas basados en fuentes de energía variables como la eólica. La adaptabilidad de este modelo le permite adaptarse rápidamente a las condiciones cambiantes y mantener un suministro energético estable y eficiente a pesar de las fluctuaciones.

Al analizar las métricas de entrenamiento del modelo, se tuvieron en cuenta varios aspectos importantes para poder evaluar su rendimiento y viabilidad en apli-


caciones reales. Los gráficos proporcionados muestran la progresión de pérdidas y recompensas durante el proceso de formación.



(a) Histograma de la pérdida de entrenamiento



(b) Histograma de la recompensa de entrenamiento



(c) Pérdida de entrenamiento a lo largo del tiempo



(d) Recompensa de entrenamiento a lo largo del tiempo


Figura 27: Resultados del entrenamiento.

La Figura 27a muestra que las pérdidas están concentradas alrededor de un valor específico, aproximadamente 9.0. Esta consistencia sugiere que el modelo está experimentando una estabilidad en términos de pérdida, pero también puede indicar que no está mejorando significativamente su rendimiento durante el entrenamiento.

La Figura 27b revela una variabilidad considerable en las recompensas obtenidas, con la mayoría centrada alrededor de 0, pero con valores negativos y positivos significativos. Esta variabilidad indica que el modelo tiene fluctuaciones importantes en su rendimiento, experimentando tanto éxitos como fracasos a lo largo del proceso de entrenamiento.

La Figura 27c indica que la pérdida se mantiene constante y alta durante todo el período de entrenamiento. Esto puede ser una señal de que el modelo no está aprendiendo de manera efectiva o se ha estancado en un punto de pérdida elevado, lo cual es preocupante para la mejora continua del modelo.


La Figura 27d muestra una fluctuación considerable en las recompensas, con picos altos y caídas pronunciadas, especialmente alrededor del paso 1000. Este patrón sugiere que el modelo está explorando diferentes políticas de aprendizaje, pero no está convergiendo hacia una solución estable y óptima.




(a) Histograma de la pérdida de entrenamiento



(b) Histograma de la recompensa de entrenamiento



(c) Pérdida de entrenamiento a lo largo del tiempo



(d) Recompensa de entrenamiento a lo largo del tiempo

Figura 28: Resultados del entrenamiento definitivo.

La Figura 28a muestra que las pérdidas están concentradas en un rango muy estrecho, entre 0.986 y 0.998. Esta consistencia sugiere que el modelo tiene un rendimiento estable en términos de pérdida durante el proceso de entrenamiento, lo que es una buena señal de que no hay grandes variaciones en la eficacia del modelo en diferentes etapas del entrenamiento.

La Figura 28b revela que la distribución de las recompensas es mucho más variada. La mayoría de las recompensas se centran alrededor de 0, pero también hay valores significativos tanto en el extremo negativo (-1500) como en el positivo (1500). Esto indica que el modelo experimenta fluctuaciones importantes en su rendimiento, con algunos episodios exitosos y otros no tanto.

La Figura 28c muestra que la pérdida de entrenamiento a lo largo del tiempo disminuye de manera constante desde aproximadamente 0.998 hasta 0.986. Este descenso continuo es una señal positiva de que el modelo está aprendiendo y mejorando su rendimiento a medida que avanza el entrenamiento.

La Figura 28d muestra que, aunque la recompensa de entrenamiento a lo largo del tiempo inicial mostraba fluctuaciones significativas (Figura 27b), en esta nueva figura la recompensa se mantiene en una línea constante alrededor de -225. Esta falta de variabilidad puede sugerir que el modelo ha alcanzado una estabilidad en términos de recompensa, aunque el valor negativo indica que aún puede no estar funcionando de manera óptima.

4.5. Resultados del Caso de Estudio

En este apartado, se presentan y analizan los resultados obtenidos del desarrollo y la implementación del entorno de simulación en Unity para la gestión de redes de distribución energética. Los resultados se obtuvieron tras someter el modelo a diversos escenarios de producción y consumo energético, utilizando datos reales y técnicas avanzadas de inteligencia artificial.

4.5.1. Eficiencia Energética

La eficiencia energética ha sido una de las métricas principales evaluadas. Esta métrica mide la cantidad de energía producida que es efectivamente utilizada por los consumidores finales, en lugar de perderse durante los procesos de transmisión y distribución. La simulación demostró que el modelo es capaz de gestionar la red de manera eficiente, con una alta proporción de la energía generada llegando a los consumidores. Esto es fundamental para la viabilidad del modelo en aplicaciones reales, donde la maximización del uso de energía tiene importantes implicaciones económicas y ambientales.

4.5.2. Reducción de Pérdidas

Otra métrica clave evaluada fue la reducción de pérdidas de energía. El modelo mostró una capacidad significativa para minimizar las pérdidas de energía que ocurren inevitablemente durante la transmisión y distribución. Al utilizar datos reales del aerogenerador y ajustar la curva de potencia, el modelo pudo optimizar la generación y distribución de energía, reduciendo las pérdidas y mejorando la eficiencia general del sistema. Este aspecto es crucial para la sostenibilidad y la rentabilidad a largo plazo de la red de distribución energética.

4.5.3. Adaptabilidad del Sistema

La adaptabilidad del sistema se evaluó en términos de su capacidad para responder a cambios en la demanda y oferta de energía. Esta métrica es especialmente importante en sistemas que dependen de fuentes de energía variables, como la eólica. El modelo demostró una alta capacidad de adaptación, ajustando rápidamente la producción y distribución de energía en respuesta a las fluctuaciones en las condiciones del viento y la demanda de los consumidores. Esta adaptabilidad garantiza un suministro estable y eficiente de energía, incluso en escenarios dinámicos y cambiantes.

4.5.4. Análisis de Gráficos y Datos

El análisis de los gráficos y datos generados durante la simulación proporciona información detallada sobre el rendimiento del modelo:

- **Histograma de la Pérdida de Entrenamiento:** La pérdida de entrenamiento se concentró en un rango estrecho, lo que indica un rendimiento estable y consistente del modelo durante el entrenamiento.
- **Histograma de la Recompensa de Entrenamiento:** La distribución de las recompensas fue variada, reflejando tanto episodios exitosos como fracasos, lo cual es indicativo de un proceso de aprendizaje dinámico.
- **Pérdida de Entrenamiento a lo Largo del Tiempo:** La pérdida disminuyó de manera constante a lo largo del tiempo, lo que sugiere que el modelo estaba aprendiendo y mejorando su rendimiento progresivamente.
- **Recompensa de Entrenamiento a lo Largo del Tiempo:** La recompensa mostró fluctuaciones significativas, pero tendió a estabilizarse, lo que indica que el modelo estaba explorando diferentes estrategias de aprendizaje.

4.5.5. Implementación de Algoritmos de IA

El uso de algoritmos de inteligencia artificial, específicamente de aprendizaje por refuerzo, permitió al modelo ajustar la producción de energía en tiempo real, mejorando la eficiencia operativa y reduciendo el desperdicio energético. El agente de IA demostró una alta capacidad de adaptación y optimización, ajustando sus estrategias basándose en datos en tiempo real y mejorando continuamente sus decisiones a lo largo del tiempo.




Figura 29: Muestra de datos

Los datos a implementar se muestran en el gráfico 29, que ilustra la variación de tres variables a lo largo de un período de 24 horas: la potencia generada (Pw), la carga eléctrica (Load), y el precio de la electricidad en tiempo real (RTP). La curva roja representa la generación de energía solar, que comienza a aumentar desde las 5:00 horas, alcanzando su pico alrededor de las 11:00 horas con aproximadamente 4000 kW, y disminuye nuevamente hasta las 17:00 horas. Por otro lado, la curva azul

muestra la demanda de electricidad, que se mantiene baja durante la madrugada, incrementándose gradualmente hasta alcanzar un máximo alrededor de las 18:00 horas con aproximadamente 3000 kW, antes de reducirse lentamente.

Además, la curva negra que representa el precio de la electricidad en tiempo real inicia con un valor bajo de aproximadamente 35 \$/kWh en las primeras horas del día, experimenta un aumento significativo alcanzando un primer pico alrededor de las 10:00 horas, se reduce ligeramente y luego sube nuevamente para alcanzar un segundo pico cerca de las 18:00 horas. Este comportamiento sugiere una correlación entre la demanda de electricidad y el aumento del precio en las horas de mayor consumo. La generación de energía solar alcanza su punto máximo durante el mediodía, cuando la demanda aún no ha alcanzado su pico. Estos datos proporcionan una visión clara de cómo la generación de energía solar, la demanda eléctrica y los precios en tiempo real interactúan a lo largo del día, subrayando la importancia de sincronizar la producción de energía renovable con los patrones de consumo para optimizar la eficiencia y reducir costos.




Figura 30: Acciones de ESS en caso 10 días

La figura 30 detalla la variación de la potencia generada por energía eólica (Wind), la carga eléctrica (Load), y el precio de la electricidad en tiempo real (RTP) a lo largo de un período de diez días. Estos resultados son generados por tres algoritmos de gestión de energía: control predictivo con programación lineal y conocimiento de pronósticos (MPCLPF), aprendizaje por refuerzo averso al riesgo sin conocimiento futuro (RARL), y aprendizaje por refuerzo buscador de riesgo sin conocimiento futuro (RSRL). Para evaluar la efectividad de los algoritmos propuestos. La batería de almacenamiento de energía utilizada en el experimento es una batería de iones de litio con una potencia nominal de 1000 kW, una capacidad energética nominal de 5000 kWh y una eficiencia de carga y descarga del 90 %.

Los algoritmos RARL y RSRL utilizados, que aunque pueden tomar decisiones apropiadas en cuanto a los tiempos de carga y descarga, presentan rampas en la potencia que no son óptimas para la operación saludable de la batería. Todos los algoritmos logran almacenar el excedente de energía eólica utilizando la capacidad disponible de la batería, maximizando así los beneficios económicos. Estos resultados subrayan el potencial de los algoritmos de aprendizaje por refuerzo para adaptarse y optimizar en escenarios en tiempo real.

La figura muestra un gráfico que detalla la variación del estado de carga (SOC) de una batería, el precio medio y el precio instantáneo de la electricidad, la potencia generada por energía eólica, la carga eléctrica y las acciones de carga/descarga a lo largo de un período de tiempo. Los algoritmos de aprendizaje por refuerzo (RL),

como el aprendizaje por refuerzo averso al riesgo (RARL) y el aprendizaje por refuerzo buscador de riesgo (RSRL), toman decisiones de carga y descarga (representadas por las barras negras) basadas en las fluctuaciones del precio de la electricidad, la generación de energía eólica y la demanda de carga. Estos algoritmos aprenden a optimizar las acciones para maximizar las recompensas acumuladas, equilibrando la carga y descarga de la batería para aprovechar los precios bajos y la disponibilidad de energía eólica, mientras minimizan los costos durante los periodos de alta demanda y precios elevados.

4.5.6. Estadísticas Descriptivas y Correlaciones

Para complementar el análisis gráfico, se presentan a continuación las estadísticas descriptivas y las correlaciones entre las principales variables del estudio. Estas tablas proporcionan una visión cuantitativa de cómo interactúan las variables clave en el sistema de gestión de energía.

Tabla 4: Estadísticas Descriptivas de las Variables

	WindSpeed	WindDirection	PowerOutput	EnergyConsumption	EnergyStorage
count	175195	175195	175195	175195	175195
mean	20.34	179.96	3933.85	4998.66	806.69
std	12.11	18.66	3498.37	577.39	855.10
min	0.00	88.86	0.00	4000.01	0.00
25 %	10.82	167.56	0.00	4497.57	0.00
50 %	20.33	179.97	3961.79	4998.35	446.71
75 %	30.02	192.36	7580.00	5498.55	1738.20
max	40.00	266.55	7580.00	5999.99	2000.00

La tabla 4 muestra las estadísticas descriptivas de las principales variables involucradas en el estudio. Estas estadísticas proporcionan un resumen general del comportamiento de las variables durante el período de simulación, incluyendo la media, desviación estándar, valores mínimos y máximos, y los percentiles.

Tabla 5: Correlaciones entre las Variables

	WindSpeed	WindDirection	PowerOutput	EnergyConsumption	EnergyStorage
WindSpeed	1.000	0.0003	0.244	0.000	0.000
WindDirection	0.0003	1.000	0.002	0.005	0.005
PowerOutput	0.244	0.002	1.000	-0.002	-0.002
EnergyConsumption	0.000	0.005	-0.002	1.000	1.000
EnergyStorage	0.257	-0.0002	0.910	-0.105	1.000

La tabla 5 muestra las correlaciones entre las variables clave. Las correlaciones proporcionan una medida de la relación lineal entre las variables, donde valores cercanos

a 1 o -1 indican una fuerte relación positiva o negativa, respectivamente. Por ejemplo, la alta correlación entre la ‘PowerOutput’ y la ‘EnergyStorage’ (0.910) sugiere que la salida de potencia tiene una fuerte influencia en el almacenamiento de energía.

4.6. Discusión

El rendimiento de dos algoritmos de aprendizaje por refuerzo (RL): el aprendizaje por refuerzo averso al riesgo (RARL) y el aprendizaje por refuerzo buscador de riesgo (RSRL). En términos de la probabilidad de que el estado de carga (SOC) esté por debajo del objetivo, RARL muestra una probabilidad del 0.55 %, indicando que en raras ocasiones no mantiene el SOC por encima del objetivo, lo que podría ser debido a su enfoque conservador. En contraste, RSRL presenta una probabilidad significativamente mayor del 20.15 %, sugiriendo que, aunque este algoritmo es más agresivo en la búsqueda de beneficios, compromete la estabilidad del SOC con mayor frecuencia, lo cual puede impactar negativamente la vida útil de la batería.

En cuanto al beneficio económico diario promedio, RARL obtiene \$37.01, reflejando una menor eficiencia en la optimización económica en comparación con RSRL, debido a su carácter averso al riesgo que prioriza la estabilidad sobre la maximización de beneficios. Por otro lado, RSRL logra un beneficio económico de \$77.14, superando a RARL significativamente. Esto destaca la capacidad de RSRL para maximizar los beneficios económicos mediante una estrategia más arriesgada, adaptándose mejor a las condiciones dinámicas y en tiempo real. Sin embargo, este enfoque viene con el riesgo de comprometer la estabilidad del SOC, lo que debe ser gestionado cuidadosamente para evitar daños a largo plazo en la batería.

4.7. Conclusión del Caso de Estudio

El caso de estudio demuestra la viabilidad y efectividad de utilizar técnicas de IA y simulaciones en Unity para optimizar redes de distribución energética. Los resultados obtenidos proporcionan una base sólida para futuras investigaciones y desarrollos en este campo, destacando la importancia de la simulación interactiva y la inteligencia artificial en la gestión eficiente de la energía.

5. Conclusiones

El estudio analizó el uso de técnicas de inteligencia artificial y el uso de plataformas de simulación basadas en motores de videojuegos como *Unity* para optimizar la gestión y operación de redes distribuidas de energía.

Gracias al enfoque metodológico y la implementación de modelos de simulación, es posible comprender cómo estas tecnologías pueden resolver problemas relacionados con la integración de fuentes de energía renovables y la gestión de la cantidad de energía. Los resultados destacan la capacidad de los algoritmos de aprendizaje por

refuerzo y otras técnicas para mejorar la eficiencia operativa de la red minimizando la pérdida de energía y optimizando la carga dinámica en condiciones cambiantes. Además, la simulación en *Unity* proporciona un entorno controlado y visualmente accesible para probar y validar estrategias de administración de energía sin los riesgos asociados con los sistemas reales.

Esta investigación tiene como objetivo contribuir a los avances académicos y técnicos en los campos de la ingeniería eléctrica y la informática proponiendo una hoja de ruta factible para mejorar la gestión de la red energética, facilitando la transición de manera más efectiva y sostenible a fuentes de energía renovables. Sin embargo, el estudio también reconoce las limitaciones de la simulación y la necesidad de investigaciones futuras para mejorar los métodos y ampliar el uso de la simulación a situaciones más complejas y diversas.

De cara al futuro, se recomienda seguir explorando nuevas oportunidades de modelado, así como integrar nuevas tecnologías como el aprendizaje profundo y los gemelos digitales para mejorar aún más la precisión y eficiencia de las soluciones energéticas. Asimismo, enfatiza la importancia de la colaboración interdisciplinar, reuniendo a expertos en energía, ingeniería e informática para abordar los desafíos energéticos globales con soluciones innovadoras y sostenibles.

A través de estos esfuerzos, se espera que este trabajo sea un primer paso hacia desarrollos futuros y contribuya a crear sistemas energéticos más inteligentes, más confiables y más adaptables, que puedan satisfacer las necesidades de un mundo energético sostenible.

Referencias

- [1] D. O. Abdeslam. *Smart Meters: Artificial Intelligence to Support Proactive Management of Energy Consumption*. de Lecture Notes in Energy, 2023.
[Citado en págs. 3 y 4.]
- [2] M. Adnan. The future of energy storage: Advancements and roadmaps for lithium-ion batteries. *International Journal of Molecular Sciences*, 24(8), 2023.
[Citado en pág. 24.]
- [3] N. M. Ashraf, M. R. S., and R. M. Optimizing hyperparameters of deep reinforcement learning for autonomous driving based on whale optimization algorithm. *PLoS ONE*, 16(6), 2021.
[Citado en pág. 29.]
- [4] Heluany Jessica B. and Gkioulos Vasileios. A review on digital twins for power generation and distribution. *International Journal of Information Security*, 23(2):1171–1195, Apr 2024.
[Citado en pág. 2.]
- [5] Clausen Christian Skafte Beck, Ma Zheng Grace, and Jørgensen Bo Nørregaard. Can we benefit from game engines to develop digital twins for planning the deployment of photovoltaics? *Energy Informatics*, 5(4):42, Dec 2022.
[Citado en págs. 1 y 17.]
- [6] Zoey Chen, Aaron Walsman, Marius Memmel, Kaichun Mo, Alex Fang, Karthikeya Vemuri, Alan Wu, Dieter Fox, and Abhishek Gupta. Urdformer: A pipeline for constructing articulated simulation environments from real-world images, 2024.
[Citado en pág. 21.]
- [7] H. T. D. b. *D. N. V. c. d. D. K. a*, 292, 2023.
[Citado en pág. 19.]
- [8] Y. C. D., P. S., T. S., and Scott M. Jordan. Evaluating the performance of reinforcement learning algorithms. In *Thirty-seventh International Conference on Machine Learning*, page 30, 2020.
[Citado en pág. 29.]
- [9] J. S. F. Z. LuPing Dai. Development status and application analysis of new energy photovoltaic power generation energy market based on artificial intelligence. *International Journal of Low-Carbon Technologies*, 19:351–358, 2024.
[Citado en pág. 4.]
- [10] Energía. System and software engineering. <https://www.gtd.eu/es/blog/generacion-integracion-de-las-energias-renovables-en-la-red-de-distribucion>, January 2013. [Último acceso: 05 06 2024].
[Citado en págs. IV y 25.]
- [11] J. D. J. H. A. H. and . V. H. Kateryna Kovbasiuk. *A Digital Twin for Remote Learning: A Case Study*. de Advances in Design, Simulation and Manufacturing VI, 2023.
[Citado en pág. 18.]
- [12] Szczepaniuk Hubert and Szczepaniuk Edyta Karolina. Applications of artificial intelligence algorithms in the energy sector. *Energies*, 16(1), 2023.
[Citado en pág. 2.]

- [13] Vidyakant Jha, Appasani Bhargav, Gupta Deepak, Ramavath Srinivas, and Khan Mohammad Shoeb. *Machine Learning and Deep Learning Approaches for Energy Management in Smart Grid 3.0*, pages 121–151. none, 09 2023. [Citado en pág. 1.]
- [14] Keil Julian, Edler Dennis, Schmitt Thomas, and Dickmann Frank. Creating immersive virtual environments based on open geospatial data and game engines. *KN - Journal of Cartography and Geographic Information*, 71(1):53–65, Mar 2021. [Citado en pág. 1.]
- [15] S. M. F. A. S. R. T. S. S. V. K. A. R, 12:1301, 2023. [Citado en pág. 19.]
- [16] M. Kiran. Hyperparameter tuning for deep reinforcement learning applications. Scientific Networking Division Lawrence Berkeley National Laboratory USA. [Citado en pág. 29.]
- [17] Surendra Kumar, Umesh Pathak, Astha, and Bhupesh Bhatia. *Achieving Peak Energy Efficiency in Smart Grids Using AI and IOT*, pages 123–135. none, 11 2023. [Citado en pág. 2.]
- [18] C. Z. P. Z. W. L. X. W. Y. L. S. X. Ding Liu. Deep reinforcement learning for real-time economic energy management of microgrid system considering uncertainties. *Frontiers in Energy Research*, 11, 2023. [Citado en pág. 19.]
- [19] Xiyuan Liu, J. W., and C. S. Efficient hyperparameters optimization through model-based reinforcement learning with experience exploiting and meta-learning. *Soft Computing*, 27:8661–8678, April 2023. [Citado en pág. 29.]
- [20] Dai LuPing, Shen JiaYi, and Zhang FeiFei. Development status and application analysis of new energy photovoltaic power generation energy market based on artificial intelligence. *International Journal of Low-Carbon Technologies*, 19:351–358, Feb 2024. [Citado en pág. 3.]
- [21] M. M. N. P. . P. R. S, 81:30–39, 2015. [Citado en pág. 19.]
- [22] Talaat M., Elkholy M., Alblawi Adel, and Said Taghreed. Artificial intelligence applications for microgrids integration and management of hybrid renewable energy sources. *Artificial Intelligence Review*, pages 1–55, 02 2023. [Citado en pág. 1.]
- [23] Z. M. a. B. N. J, 39, 2022. [Citado en págs. 17 y 18.]
- [24] Z. Ma and J. Korsgaard y B. N, 2019. [Citado en pág. 19.]
- [25] R. Marques. Smart grids: lo que hay que tener en cuenta para los próximos años. <https://latam.tivit.com/blog/smart-grids-lo-que-hay-que-tener-en-cuenta-para-los-proximos-anos>, March 2020. [Último acceso: 16 06 2024]. [Citado en págs. IV y 31.]
- [26] R. Martín-Martín. igibson: A simulation environment to train ai agents in large realistic scenes. none, 2020. [Citado en pág. 21.]

- [27] M. Merino. Conceptos inteligencia artificial que aprendizaje refuerzo. <https://www.xataka.com/inteligencia-artificial/conceptos-inteligencia-artificial-que-aprendizaje-refuerzo>, January 2019. [Último acceso: 01 07 2024]. [Citado en págs. IV y 30.]
- [28] Fayyazi Mojgan, Sardar Paramjotsingh, Thomas Sumit I., Roonak Daghigh, Ali Jamali, Thomas Esch, Hans Kemper, Reza Langari, and Hamid Khayyam. Artificial intelligence/machine learning in energy management systems, control, and optimization of hydrogen fuel cell vehicles, 2023. [Citado en pág. 3.]
- [29] A. N. and M. Biswas. Unity ml-agents. In *Neural Networks in Unity*, pages 27–67. none, 2018. [Citado en pág. 26.]
- [30] none. Cities: Skylines map generator. <https://heightmap.skydark.pl/>. Accessed: 2024-7-9. [Citado en pág. 21.]
- [31] B. E. (Owner). Kaggle. <https://www.kaggle.com/datasets/berkerisen/wind-turbine-scada-dataset>, 2018. [Citado en pág. 25.]
- [32] A. J. J. P. V. H. H. and . M. T. V., 2023. [Citado en pág. 18.]
- [33] R. P.-V., J. M. C. T., and Laura Almón-Manzano. Deep reinforcement learning in agents’ training: Unity ml-agents. In *Bio-inspired Systems and Applications: from Robotics to Ambient Intelligence*, pages 391–400. Springer Suiza, Puerto de la Cruz, Tenerife, 2022. [Citado en pág. 28.]
- [34] A. P. A. K. S. M. Utkarsh Pandey. Applications of artificial intelligence in power system operation. *control and planning: a review, Clean Energy*, 7:1199–1218, 2023. [Citado en pág. 4.]
- [35] T. W. Power and The Wind Power. 17 07 2023. [En línea]. Available: https://www.thewindpower.net/turbine_es_600_enercon_e126-7580.php. [último acceso: 10, 2023]. [Citado en pág. 20.]
- [36] Hannah Ritchie, Pablo Rosado, and Max Roser. Energy production and consumption. *Our World in Data*, 2020. <https://ourworldindata.org/energy-production-consumption>. [Citado en pág. 1.]
- [37] Bakare Mutiu Shola, Abdulkarim Abubakar, Zeeshan Mohammad, and Shuaibu Aliyu Nuhu. A comprehensive overview on demand side energy management towards smart grids: challenges, solutions, and future direction. *Energy Informatics*, 6(1):4, Mar 2023. [Citado en pág. 2.]
- [38] S. Stavrev and D. G. Reinforcement learning techniques in optimizing energy systems. *Applications of Machine Learning and Artificial Intelligence in Modern Power and Energy Systems*, 13(8), 2024. [Citado en pág. 30.]
- [39] Mischos Stavros, Dalagdi Eleanna, and Vrakas Dimitrios. Intelligent energy management systems: a review. *Artificial Intelligence Review*, 56:1–40, Mar 2023. [Citado en pág. 3.]

- [40] Haochen Sun, F. Z., T. L., Z. P., and S. Data-driven reinforcement-learning-based hierarchical energy management strategy for fuel cell/battery/ultracapacitor hybrid electric vehicles. *Journal of Power Sources*, 455(227964), 2020. [Citado en pág. 30.]
- [41] Cristie Verina and Unterburger Matthias. *Game Engines for Urban Exploration: Bridging Science Narrative for Broader Participants*, pages 87–107. none, 10 2017. [Citado en pág. 1.]
- [42] Wang Xinlin, Wang Hao, Bhandari Binayak, and Cheng Leming. Ai-empowered methods for smart energy consumption: A review of load forecasting, anomaly detection and demand response. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 11:1–31, 09 2023. [Citado en pág. 2.]
- [43] Z., . V. G., and . C. A. Rahimpour. *Actor-Critic Learning for Optimal Building Energy Management with Phase Change Materials*. Electric Power Systems Research, 2020. [Citado en pág. 19.]
- [44] A. Z. a. A. D, 217:9, 2019. [Citado en pág. 19.]
- [45] Chunhua Zheng, L. W., L. K., X. P., and S. W. C. A deep reinforcement learning-based energy management strategy for fuel cell hybrid buses. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 9:885–897, 2022. [Citado en pág. 30.]