

Asignación de Precios Minoristas en Sistemas de Distribución con Múltiples Microrredes Usando
Aprendizaje por Refuerzo

Camilo Esteban Carrillo Valera y Jhon Héctor Sandoval Manrique

Trabajo de Grado para optar al título de Ingenieros Electrónicos

Director

Juan Manuel Rey López

Doctor en Ingeniería Electrónica

Codirector

Andrés Felipe Luna Chacón

Ingeniero Electricista

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería Electrónica

Bucaramanga

2023

Agradecimientos de Camilo Esteban Carrillo Valera

“El genio es uno por ciento de inspiración y noventa y nueve por ciento de transpiración”- Thomas Edinson.

El origen y desarrollo de este proyecto no podría haberse dado sin el impulso hacia la investigación que me dio el profesor Juan Manuel Rey, el cual hace un tiempo atrás decide invitarme a hacer parte del semillero de investigación en microrredes “ μ Grids Research” y por medio del cual me fue presentando todo el campo que tienen las microrredes en la actualidad y a futuro, es así como apenas me presenta la oportunidad de desarrollar este trabajo la acepto y propongo a mi amigo Jhon el cumplir este nuevo proyecto. Agradezco también a la Universidad Industrial de Santander por siempre tener las herramientas necesarias para conseguir la información que se requirió en el proyecto. Agradecimiento al Ing. Andrés Luna por brindarnos su punto de vista desde la experiencia en la industria de los sistemas de distribución. Y además, agradecer especialmente a Consuelo, Amparo y mi familia por el acompañamiento a lo largo de este proyecto, también a Silvia Roza por acompañarme e impulsarme a seguir cuando el proyecto se complicaba. A la distancia gracias Nohora por el apoyo financiero y emocional.

Finalmente, quiero dedicar este trabajo a las personas que me ayudaron a ser quien soy y que ya no están: Bernard Maurice y Cecilia Valera. Y también a cada uno de los compañeros del semillero μ Grids Research que sigan adelante y que hagamos más por el desarrollo de las microrredes y alternativas verdes en Colombia y el mundo.

Agradecimientos de Jhon Héctor Sandoval Manrique

Quiero expresar mi profundo agradecimiento primero a Dios y a la Virgencita del Milagro por las bendiciones y fortaleza que me brindaron a lo largo de este camino. Su guía y protección han sido fundamentales en cada paso que he dado. Agradezco al profe Juan Manuel Rey por el apoyo y la confianza con este proyecto, espero haber cumplido sus expectativas. Fue muy interesante. A mis queridos padres Mariela y Héctor, les agradezco de corazón por su apoyo incondicional y su amor inquebrantable. Han sido mi motor, mi inspiración y mi apoyo constante durante toda mi vida. Sin ustedes, este logro no habría sido posible. Gracias por creer en mí y por alentarme a seguir adelante en todo momento. Este logro es para ustedes y por ustedes. A mis hermanos Vane, Fercho y Sergio, les agradezco por los mensajes de aliento y el amor que me han demostrado a lo largo de este proceso, sus palabras de ánimo y su presencia han sido un gran impulso para mí. A mi angelito en el cielo por nunca dejarme solo, gracias por estar siempre a mi lado. A mi novia Natalia B, quiero agradecerle por sentirse orgullosa de mi y por recordarme siempre que todo el esfuerzo y dedicación valdría la pena. Su apoyo incondicional y su amor me han dado la fuerza necesaria para superar cualquier desafío. Gracias por ser mi compañera de vida. Finalmente, a mis abuelos, tíos, primos y demás familiares, por su aliento, por estar presentes en mi vida. Sus palabras y su apoyo han sido un estímulo adicional en mi camino hacia el éxito.

De corazón, este trabajo de grado no habría sido posible sin el amor y el apoyo de todas las personas mencionadas anteriormente. Estoy profundamente agradecido por su presencia en mi vida y por haber sido una parte integral de este importante logro.

Tabla de Contenido

Introducción	12
1. Objetivos	14
2. Sistema de distribución con múltiples microrredes	15
2.1. Microrredes	15
2.1.1. Potencia producida por un panel solar fotovoltaico	17
2.1.2. Potencia producida por un generador eólico	18
2.1.3. Perfil de carga	19
2.1.4. Potencia producida por el generador Diesel	19
2.1.5. Despacho de la microrred	21
2.2. Flujo de potencia del sistema de distribución	23
3. Aprendizaje por refuerzo	24
3.1. Definición de recompensa	26
3.1.1. Técnica de entrenamiento basada en el método de Monte Carlo	29
4. Fase de entrenamiento	30
4.1. Creación base de datos	30
4.2. Acciones y Estados de entrenamiento	32

PRECIOS MINORISTAS EN SISTEMA DE DISTRIBUCIÓN CON MM POR AR	5
4.3. Entrenamiento	32
4.4. Análisis de los parámetros de entrenamiento	33
5. Análisis y resultados	36
6. Conclusiones	39
7. Recomendaciones y trabajo futuro	40
Referencias Bibliográficas	42

Lista de Figuras

Figura 1.	Concepto de Microrred.	16
Figura 2.	Día semilla y día sintético de carga en por unidad.	19
Figura 3.	Ficha técnica del generador Diesel (Clifford-Power, 2023).	21
Figura 4.	Arquitectura del modelo de optimización de la microrred.	21
Figura 5.	Topología de sistema de distribución de estudio.	23
Figura 6.	Esquema básico de la técnica Aprendizaje por Refuerzo.	25
Figura 7.	Gráfica con el comportamiento de las potencias intercambiadas.	28
Figura 8.	Día semilla y día sintético de irradiación solar.	30
Figura 9.	Día semilla y día sintético de velocidad del viento.	31
Figura 10.	Gráfica de las recompensas tras barrido de pesos α con 10.000 épocas	35
Figura 11.	Gráfica de las recompensas tras barrido de épocas	36
Figura 12.	Gráfica comparativa de potencias entre las políticas π_{Modelo} y $\pi_{Precio=0.033}$	37
Figura 13.	Comparación de las diferentes políticas de precios.	38

Lista de Tablas

Tabla 1.	Parámetros de las microrredes	17
Tabla 2.	Parámetros de las líneas del sistema de distribución	24
Tabla 3.	Recompensas con diferentes políticas	38

Glosario

Sistema de Distribución: Es la etapa final del sistema eléctrico que se encarga de llevar la energía eléctrica desde las subestaciones de transmisión hacia los usuarios finales. Está constituido por elementos tales como las líneas de distribución, transformadores y otros componentes que distribuyen la electricidad a través de diferentes áreas geográficas (Gonen, 2014).

Flujo de potencia: Se refiere a la dirección y magnitud de la potencia que fluye desde las fuentes de generación hacia los usuarios finales, a través de un sistema de distribución o transmisión, teniendo en cuenta las pérdidas y la capacidad de los componentes del sistema (Short, 2014).

Relación de Potencia Pico a Promedio (PAR): De su traducción del inglés "Peak-to-Average-Ratio" corresponde a la relación entre la potencia máxima y la potencia promedio de el registro de una cantidad de potencias definidas en un intervalo de tiempo. Una alta PAR indica fluctuaciones significativas en la potencia que en cierta medida pueden afectar la estabilidad del sistema y hacer necesario un sobredimensionamiento de los componentes eléctricos que se ven afectados por estos picos de potencia (Liu et al., 2014).

Operador de Red (OR): Es la entidad o unidad responsable de gestionar y operar el sistema de distribución de energía eléctrica. Su función principal es garantizar un suministro confiable y eficiente de energía a los usuarios finales, coordinando la generación, el transporte, la distribución de la energía eléctrica y la asignación de precios minoristas (Willis, 2004) (Short, 2014).

Precio minorista: Se refiere al costo que se cobra a los consumidores finales por la energía sumi-

nistrada a través de la red eléctrica. Este, tiene asociado diferentes componentes, como el costo de generación de la electricidad, los costos de transmisión y distribución de la energía, así como los impuestos y cargos asociados. El precio minorista puede variar según la zona geográfica, el tipo de contrato y la demanda de energía en determinados momentos del día (Sui et al., 2022).

Entrenamiento de un modelo: Se refiere al proceso de ajustar los parámetros de un modelo de "Machine Learning" utilizando un conjunto de datos de entrenamiento. Durante este proceso, el modelo aprende a relacionar las características de entrada con las salidas deseadas, mejorando su capacidad para realizar predicciones (Geron, 2021).

Épocas de entrenamiento: Una época de entrenamiento representa una iteración completa por todo el conjunto de datos durante el proceso de entrenamiento de un modelo. Durante cada época, el modelo utiliza los datos de entrenamiento para realizar predicciones, calcular el error y ajustar sus parámetros mediante algoritmos de optimización. El número de épocas es un hiperparámetro que determina cuántas veces se iterará sobre el proceso de ajuste (Goodfellow et al., 2016).

Verificación de un modelo: Se refiere a la evaluación del rendimiento del modelo en un conjunto de datos separado llamado conjunto de verificación. Este conjunto de datos se utiliza para medir qué tan bien generaliza el modelo frente a datos no vistos previamente. La verificación ayuda a detectar si el modelo sobre ajusta los datos de entrenamiento y si proporciona una estimación adecuada frente a situaciones del mundo real (Geron, 2021).

Resumen

Título: Asignación de Precios Minoristas en Sistemas de Distribución con Múltiples Microrredes Usando Aprendizaje por Refuerzo *

Autor: Camilo Esteban Carrillo Valera y Jhon Héctor Sandoval Manrique **

Palabras Clave: Microrredes, Operador de Red, Aprendizaje por Refuerzo, Método Monte Carlo, Energía Eléctrica.

Descripción: En esta investigación se propone desarrollar un algoritmo para la asignación de los precios minoristas en un sistema de distribución con múltiples microrredes usando la técnica de aprendizaje por refuerzo. Para esto, se plantea una topología en específico de un sistema de distribución con 4 microrredes conectadas que tienen la posibilidad de comprar o vender energía a la red principal para satisfacer su demanda. Desde la perspectiva del OR, el objetivo es maximizar las ganancias por compra/venta de energía mientras se minimiza la PAR de la demanda. Las microrredes compuestas por fuentes renovables y fuentes despachables, determinan la potencia intercambiada con la red a través del planteamiento de un problema de optimización en el que se busca minimizar sus costos operativos. Para el análisis de flujos de potencia del sistema de distribución se utiliza la librería PandaPower de Python. Se entrena una estrategia de aprendizaje por refuerzo mediante el método de Monte Carlo con el fin de seleccionar una política de precios diarios. Finalmente, los resultados se comparan con políticas de precio constante, evaluando y concluyendo sobre las mejoras obtenidas.

* Trabajo de grado

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y telecomunicaciones. Director: Juan Manuel Rey López, PhD. en Ingeniería Electrónica. Codirector: Andrés Felipe Luna Chacón, Ingeniero Electricista.

Abstract

Title: Retail Pricing in Multi-Microgrid Distribution Systems Using Reinforcement Learning *

Author: Camilo Esteban Carrillo Valera y Jhon Héctor Sandoval Manrique **

Keywords: Microgrids, Distribution System Operator, Reinforcement Learning, Monte Carlo Method, Electrical Energy.

Description: This research aims to develop an algorithm for retail price definition in a multi-microgrid distribution system using reinforcement learning. A specific topology is proposed for a distribution system with 4 connected microgrids that buy or sell energy to the main grid to meet their demand. From the perspective of the Distribution System Operator (DSO), the objective is to maximize the profits from energy transactions while minimizing the Peak-to-Average-Power-Ratio (PAR) of the demand. The microgrids composed of renewable sources and dispatchable sources, exchange energy with the grid according to an optimization dispatch problem formulation that seeks to minimize operating costs. Power flows are solved in Python using PandaPower library. A reinforcement learning strategy is trained using Monte Carlo method to select a daily retail pricing policy. Finally, the results are compared with constant price policies, evaluating and concluding on the improvements obtained.

* Bachelor Thesis

** Faculty of Physico-Mechanical Engineering. School of Electrical, Electronic, and Telecommunications Engineering. Director: Juan Manuel Rey López, PhD. in Electronic Engineering. Co - director: Andrés Felipe Luna Chacón, Electrical Engineer.

Introducción

En el contexto de la creciente demanda de consumo de energía en la red eléctrica y la necesidad de aprovechar al máximo las fuentes de energía renovable, esta investigación se centra en el desarrollo de un algoritmo para la asignación de precios minoristas en un sistema de distribución con múltiples microrredes. El objetivo principal es abordar la problemática existente al maximizar las ganancias del OR por la venta de energía y reducir la PAR (Liu et al., 2014). Para lograr este objetivo, se propone utilizar Aprendizaje por Refuerzo, una técnica de "Machine Learning" que permite tomar decisiones garantizando buenos resultados en entornos dinámicos. En particular, se emplea el método de aprendizaje por refuerzo sin modelo (Dayan and Niv, 2008), entrenando a partir del método de Monte Carlo. Esta elección se debe a la naturaleza aleatoria de las variables involucradas, como los recursos renovables, la velocidad del viento, la radiación solar y la demanda de energía, lo cual se adapta al desarrollo de la propuesta.

El algoritmo propuesto permite al OR definir una política de precios minoristas de energía durante las 24 horas del día. Además, se espera que este enfoque de la reducción de la PAR garantice disminuir la posibilidad de sobrecargar el sistema en determinadas horas de consumo crítico. En este trabajo, se presenta una topología específica del sistema de distribución con cuatro microrredes conectadas que tienen la capacidad de comprar o vender energía para satisfacer sus necesidades.

La definición del valor de potencia de las fuentes despachables de las microrredes, así como de potencia intercambiada con la red, se solucionan planteando un problema de minimización del

costo de operación, mediante la librería Pyomo de Python. Por otra parte, el flujo de potencia del intercambio total de energía de las microrredes con el sistema de distribución se calcula mediante la librería PandaPower de Python. Se lleva a cabo una estrategia de entrenamiento basada en el método de Monte Carlo del aprendizaje por refuerzo para seleccionar la mejor política de precios, tomando decisiones basadas en predicciones.

Los resultados obtenidos se comparan con la simulación realizada utilizando políticas de precios constantes, lo que permite evaluar la efectividad del algoritmo propuesto. En última instancia, las conclusiones derivadas de esta investigación proporcionan una base sólida para futuros estudios, que podrían ampliar el alcance del sistema de distribución con la inclusión de más microrredes, variables adicionales y condiciones más cercanas a la realidad, como una carga trifásica desbalanceada y sistemas de almacenamiento.

1. Objetivos

Objetivo general

Diseñar un algoritmo que permita la asignación de precios minoristas en un sistema de distribución con múltiples microrredes usando la técnica de aprendizaje por refuerzo.

Objetivos específicos

Modelar los flujos de potencia de un sistema de distribución con múltiples microrredes ante un precio minorista predeterminado;

Crear un conjunto de datos sintéticos de carga y recursos energéticos;

Definir una estrategia de aprendizaje por refuerzo para la asignación de precios minoristas por parte del operador de red;

Implementar un caso de estudio de un sistema de distribución con múltiples microrredes;

Elaborar el algoritmo de la asignación de precios minoristas basado en el caso implementado.

2. Sistema de distribución con múltiples microrredes

En esta sección, se describirá la topología del sistema de distribución usado como caso de estudio, así como la configuración de las microrredes interconectadas.

2.1. Microrredes

Una microrred se refiere a un sistema de energía controlado a pequeña escala que está compuesto principalmente por recursos energéticos distribuidos como fuentes de generación de energía renovable y sistemas de almacenamiento interconectados. Las microrredes tienen la capacidad de operar tanto en conexión con la red principal como de manera aislada. Una unidad central de control de la microrred se encarga de gestionar las fuentes despachables, minimizando el costo de la operación y garantizando un suministro continuo y fiable (Olivares et al., 2014; Hossain et al., 2019; Farrokhhabadi et al., 2020). Las microrredes desempeñan un papel crucial al satisfacer las demandas energéticas locales. Una de sus características distintivas radica en su capacidad para abastecer cargas críticas que requieren un suministro constante de energía, sin depender únicamente de la red eléctrica principal.

Cuando las microrredes operan en modo conectado a la red principal, la tensión y la frecuencia de operación son determinadas por dicha red. En este escenario, la decisión de comprar o vender energía a la red principal se basa en el costo minorista y se considera el control de potencia (activa y reactiva) para operar de manera eficiente. Por otro lado, cuando las microrredes funcionan en modo aislado, los sistemas de almacenamiento de energía desempeñan un papel crucial para garantizar el equilibrio energético. Estos sistemas pueden suministrar o absorber potencia según

sea necesario. El modo aislado se activa en situaciones como mantenimiento en la red, fallos o cualquier otra circunstancia anómala que requiera desconexión de la red principal (Hossain et al., 2019).

Para el caso de estudio, se trabajó con un conjunto de microrredes que incluyen paneles solares, generadores eólicos, generadores diésel (despachable) y sus respectivas cargas como se muestra en la figura 1. En total, se utilizaron 4 microrredes con una estructura general similar. Cada microrred está compuesta por las configuraciones detalladas en la Tabla 1.

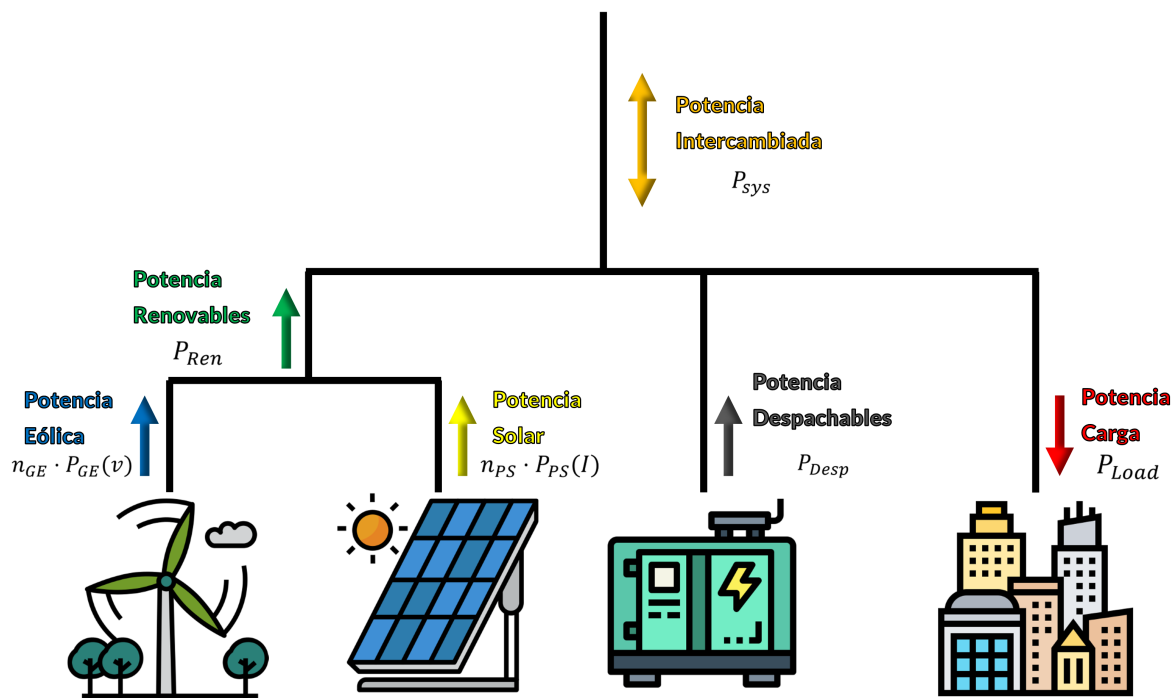


Figura 1. Concepto de Microrred.

La potencia nominal y componentes de los sistemas de energía renovable (paneles solares y generadores eólicos) de cada microrred fueron diseñados con el objetivo de garantizar una producción de energía renovable que represente aproximadamente el 30% de las cargas locales.

Tabla 1

Parámetros de las microrredes

Microrred	Números paneles solares ¹ (n_{PS})	Número generadores eólicos ² (n_{GE})	Potencia nominal [kW]
1	15	11	23
2	28	19	45
3	39	26	63
4	24	17	39

¹ La potencia nominal del panel solar es 0.306 [kW].

² La potencia nominal del generador eólico es 0.303 [kW].

A continuación se describen los modelos de potencia de cada uno de los elementos de las microrredes.

2.1.1. Potencia producida por un panel solar fotovoltaico. En el cálculo de la potencia producida por la irradiación solar, se toman en cuenta tres factores principales. El primero es el área del panel solar fotovoltaico (A_{PS}), que generalmente se expresa en metros cuadrados (m^2). Este valor representa el tamaño físico del panel y determina la cantidad de irradiación solar que puede captar.

El segundo factor es la eficiencia del panel solar fotovoltaico (η), que indica la capacidad del panel para convertir la radiación solar en potencia eléctrica. La eficiencia se expresa como un valor decimal o porcentual, y varía según el tipo y el material del panel.

El tercer factor es la irradiación solar (I), que representa la cantidad de energía solar que incide sobre el panel en un período de tiempo determinado. La radiación solar se mide en vatios por metro cuadrado (W/m^2) y depende de diversos factores como la ubicación geográfica, la estación del año, la hora del día y las condiciones climáticas (Vergara et al., 2014)(IDEAM, 2005).

Al combinar estos tres factores en el cálculo, es posible determinar la potencia producida

por el panel solar fotovoltaico. Esta fórmula permite estimar la cantidad de potencia eléctrica que puede generarse a partir de la irradiación solar captada por el panel. La fórmula básica es:

$$P_{PS}(I) = \frac{A_{PS} \cdot \eta \cdot I}{1000} \quad (1)$$

La ecuación 1 está dividida en 1000 para así obtener la potencia en unidades de (kW), donde A_{PS} se consideró como $1.7 \text{ (m}^2\text{)}$ y la eficiencia (η) de 0.18.

2.1.2. Potencia producida por un generador eólico. En el cálculo de la potencia producida por el viento, se consideran tres factores principales: el área de barrido de las aspas del aerogenerador (A_{GE}), la densidad del aire (ρ) y la velocidad del viento (v).

El área de barrido de las aspas del aerogenerador (A_{GE}) representa la superficie total que las aspas cubren al girar. Esta área determina la cantidad de aire que es capturada y utilizada para generar energía.

La densidad del aire (ρ) es una medida de la masa de aire por unidad de volumen. En el cálculo de la potencia eólica, la densidad del aire se utiliza para determinar la cantidad de masa de aire que atraviesa el área de barrido de las aspas del aerogenerador en un determinado tiempo.

La velocidad del viento (v) es la magnitud y dirección del flujo de aire. La velocidad del viento tiene un impacto directo en la cantidad de energía que puede ser capturada por las aspas del aerogenerador. A mayor velocidad del viento, mayor será la potencia generada. Otro factor que se tuvo en cuenta en este trabajo es el coeficiente de potencia (C_p) la cual es una medida de la eficiencia con la que un generador eólico puede extraer energía del viento (Vergara et al., 2014).

La ecuación básica es (Ilinca et al., 2003):

$$P_{GE}(v) = \frac{\frac{1}{2} \cdot \rho \cdot A_{GE} \cdot C_p \cdot v^3}{1000} \quad (2)$$

La ecuación 2 se divide en 1000 para obtener el resultado en unidades de (kW), donde (ρ) tiene un valor de $1.225 \text{ (kg/m}^3\text{)}$, el área de las aspas está definida como $\pi r^2 \text{ (m}^2\text{)}$ en que el radio toma el valor de 1.78 (m), la velocidad está en (m/s) y el factor de C_p representa un coeficiente de potencia con valor de 0.45.

2.1.3. Perfil de carga. Este perfil de carga proporciona el comportamiento de la demanda de la microrred, tomando valores de potencia hora a hora en por unidad (normalizada) para realizar el respectivo flujo de potencia. Estos perfiles de carga sintéticos se generarán partiendo de los valores de carga de un día semilla (Explicado en la sección 4.1).

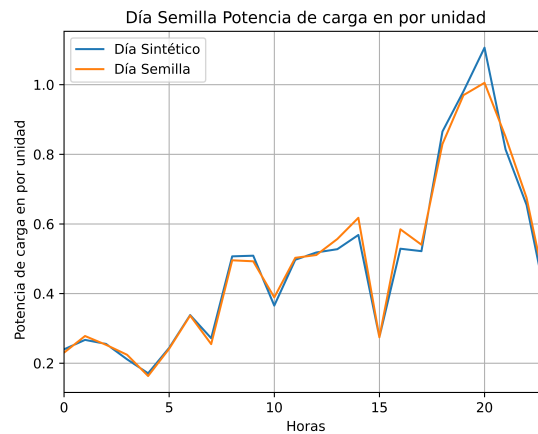


Figura 2. Día semilla y día sintético de carga en por unidad.

2.1.4. Potencia producida por el generador Diesel. La inclusión de un generador Diesel en las microrredes proporciona un respaldo confiable ante situaciones en las que las fuentes re-

novables no pueden cubrir completamente la demanda eléctrica. La operación del generador está determinada por la referencia de potencia que asigne el controlador central de la microrred. Es decir, por el valor de potencia que se defina en el despacho. El costo de operación de este generador se define mediante la siguiente ecuación cuadrática:

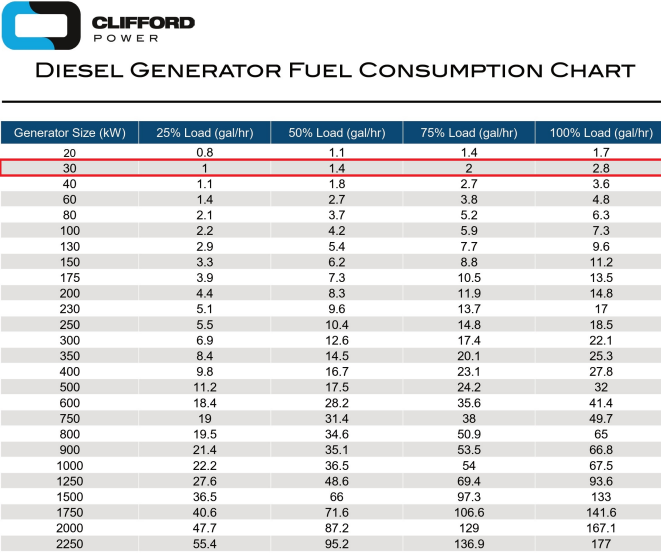
$$\$_{desp}(P_{desp}) = \$_{galon} \cdot (a \cdot P_{desp}^2 + b \cdot P_{desp} + c) \quad (3)$$

En esta ecuación, $\$_{galon}$ representa el costo por galón de Diesel en dólares, que para este trabajo se asumirá como 1.8 $[\text{USD}/\text{g}]$, P_{desp} es la potencia despachada por el generador, y las constantes a , b y c describen el comportamiento específico del generador (Du and Li, 2020).

Para el cálculo de las constantes de la ecuación, se utilizó la ficha técnica presentada en la Figura 3 que contiene información sobre los puntos operativos de un generador Diesel particular.

Como se evidencia, se tienen tres puntos de costos de operación para el generador. Utilizando el método de mínimos cuadrados, se realizaron los cálculos correspondientes para determinar las constantes de la ecuación de costos. Teniendo en cuenta que la potencia máxima que puede producir el generador es de 30 [kW], se obtuvieron los siguientes valores de constantes: $a = \frac{2}{1125} [\text{g}/\text{kW}^2]$, $b = \frac{1}{75} [\text{g}/\text{kW}]$ y $c = \frac{4}{5} [\text{g}]$, por lo que la ecuación 3 puede sustituirse con valores numéricos como

$$\$_{desp}(P_{desp}) = 1.8 \cdot \left(\frac{2}{1125} \cdot P_{desp}^2 + \frac{1}{75} \cdot P_{desp} + \frac{4}{5} \right) \quad (4)$$



CLIFFORD POWER
DIESEL GENERATOR FUEL CONSUMPTION CHART

Generator Size (kW)	25% Load (gal/hr)	50% Load (gal/hr)	75% Load (gal/hr)	100% Load (gal/hr)
20	0.8	1.1	1.4	1.7
30	1	1.4	2	2.8
40	1.1	1.8	2.7	3.6
60	1.4	2.7	3.8	4.8
80	2.1	3.7	5.2	6.3
100	2.2	4.2	5.9	7.3
130	2.9	5.4	7.7	9.6
150	3.3	6.2	8.8	11.2
175	3.9	7.3	10.5	13.5
200	4.4	8.3	11.9	14.8
230	5.1	9.6	13.7	17
250	5.5	10.4	14.8	18.5
300	6.9	12.6	17.4	22.1
350	8.4	14.5	20.1	25.3
400	9.8	16.7	23.1	27.8
500	11.2	17.5	24.2	32
600	18.4	28.2	35.6	41.4
750	19	31.4	38	49.7
800	19.5	34.6	50.9	65
900	21.4	35.1	53.5	66.8
1000	22.2	36.5	54	67.5
1250	27.6	48.6	69.4	93.6
1500	36.5	66	97.3	133
1750	40.6	71.6	106.6	141.6
2000	47.7	87.2	129	167.1
2250	55.4	95.2	136.9	177

35 YEARS CLIFFORD POWER DEPENDABILITY
GENERATOR EQUIPMENT, SERVICE, RENTAL
Contact us at any of our locations in OK, TX, AR, KS, & MO.
cliffordpower.com | 1-800-324-0066

Figura 3. Ficha técnica del generador Diesel (Clifford-Power, 2023).

2.1.5. Despacho de la microrred. En la figura 4 se evidencia los respectivos parámetros de entrada y salida de la microrred, con la cual se llevará a cabo la minimización de su costo de operación.




Figura 4. Arquitectura del modelo de optimización de la microrred.

El objetivo del problema de despacho es minimizar el costo de operación de la microrred, que está compuesto por dos términos: el costo de operación del generador $\$_{desp}$ (definido en la ecuación 4) y el costo de compra/venta de energía al sistema de distribución $\$_{sys}$ definido como

$$\$_{sys}(P_{sys}) = \$_{kWh} \cdot P_{sys} \quad (5)$$

donde $\$_{kWh}$ es el precio de energía minorista asignado en kW-h y P_{sys} es la potencia intercambiada con el sistema de distribución.

Así, el problema de despacho, en donde deben definirse las variables P_{desp} y P_{sys} , se formula como:

$$\begin{aligned} & \underset{P_{desp}, P_{sys}}{\text{mín}} \quad \{ \$_{desp} + \$_{sys} \} \\ & \text{sujeto a} \quad P_{ren} + P_{desp} + P_{sys} = P_{load} \end{aligned} \quad (6)$$

donde P_{ren} corresponde a la energía renovable producida, que se define a partir del número de paneles solares n_{PS} , la potencia producida por un panel $P_{PS}(I)$ (ecuación 1), el número de generadores eólicos n_{GE} y la potencia producida por un generador eólico $P_{GE}(v)$ (ecuación 2):

$$P_{ren} = n_{PS} \cdot P_{PS}(I) + n_{GE} \cdot P_{GE}(v). \quad (7)$$

Por su parte, P_{load} corresponde a la carga total de la microrred. Nótese que la restricción es el balance de potencia de la microrred, asumiendo pérdidas nulas en sus líneas de distribución, aproximación generalmente válida para microrredes de potencia baja y media (ver Figura 1).

Este problema de optimización es resuelto para cada microrred usando la librería Pyomo de Python. Para ser resuelto, es necesario que se especifique el precio minorista de energía $\$_{kWh}$ por parte del OR.

2.2. Flujo de potencia del sistema de distribución

Como se mencionó anteriormente, el sistema de distribución está compuesto por 4 microrredes, conectadas en un sistema radial balanceado a un nodo de interconexión a la red principal (barra Slack, barra 0) como se puede ver en la figura 5. Para el caso de estudio, se hace uso de la librería de Python llamada PandaPower, para realizar el flujo de potencia. Para utilizar esta herramienta, se cargó un modelo pre-diseñado proporcionado por la librería y se adaptó a la topología del sistema de distribución definido previamente. Este enfoque permitió aprovechar los parámetros y configuraciones predefinidas en ese modelo, evitando los posibles errores de sintaxis y de parámetros de los elementos del sistema. En la tabla 2 se registran los valores de impedancia y longitud de cada línea con cada una de las etiquetas que se evidencian en la figura 5.

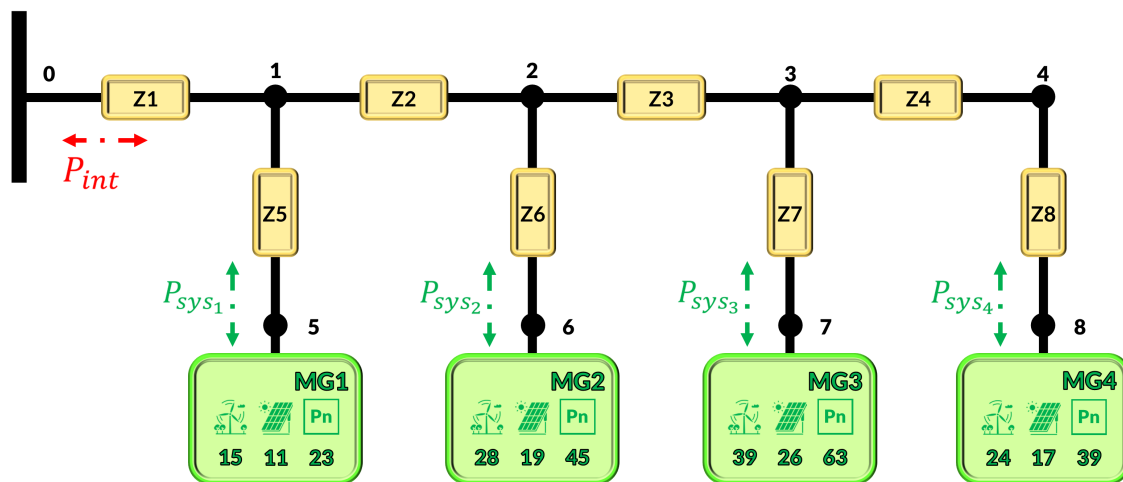


Figura 5. Topología de sistema de distribución de estudio.

Tabla 2

Parámetros de las líneas del sistema de distribución

Línea	Resistencia [Ω/km]	Reactancia [Ω/km]	Distancia [km]
Z ₁	1.60816	16.0816	1.0
Z ₂	0.33856	3.3856	1.5
Z ₃	1.57113	15.7113	1.3
Z ₄	1.57113	15.7113	1.2
Z ₅	1.48649	14.8649	1.0
Z ₆	0.57132	5.7132	1.0
Z ₇	1.57113	15.7113	1.0
Z ₈	1.57113	15.7113	1.0

¹ Valores obtenidos utilizando la herramienta de PandaPower y etiquetas de línea de la figura 5.

Para el flujo de potencia se le asignaron a las potencias intercambiadas por cada microrred (P_{sys1} , P_{sys2} , P_{sys3} y P_{sys4}) signos de acuerdo con su comportamiento. Se asumirá signo positivo si una microrred consume/compra energía y signo negativo si una microrred entrega/vende energía. Solucionando los flujos de potencia del sistema de distribución considerando las pérdidas causadas por las impedancias de las líneas, se calcula $P_{int}(t)$ que corresponde a la potencia intercambiada por el sistema de distribución en el nodo de interconexión a la red principal (nodo 0).

3. Aprendizaje por refuerzo

A medida que aumenta el interés en el uso de microrredes para la distribución de energía eléctrica proveniente de fuentes sostenibles, la gestión de estas se convierte en un desafío apasionante. En este sentido, el aprendizaje por refuerzo, "Reinforcement Learning", se presenta como una herramienta de especial interés porque a diferencia de otras técnicas, no requiere un modelo preciso del entorno de optimización para alcanzar una solución favorable. Se trata de una técnica de aprendizaje automático o "Machine Learning" que se utiliza para abordar problemas de toma de decisiones

secuenciales basados en procesos de decisión de Markov. En el aprendizaje por refuerzo, se establecen ciertos parámetros que forman la base de esta técnica. El agente aprende interactuando de forma iterativa con los estados del entorno, con el objetivo de maximizar la recompensa total obtenida. Estas recompensas son asignadas mediante un esquema cuidadosamente diseñado, a partir del cual el agente adquiere el conocimiento necesario para desarrollar una política que asigna la mejor acción a cada estado.

En la figura 6 se presenta un esquema básico de aprendizaje por refuerzo. En este enfoque, un agente interactúa con el ambiente, recibiendo información y tomando decisiones basadas en una acción **A** específica. Como resultado de esta acción, el agente obtiene una recompensa **R**, la cual se busca maximizar mediante el desarrollo de una política que guíe sus elecciones de acción en cada estado **S**.

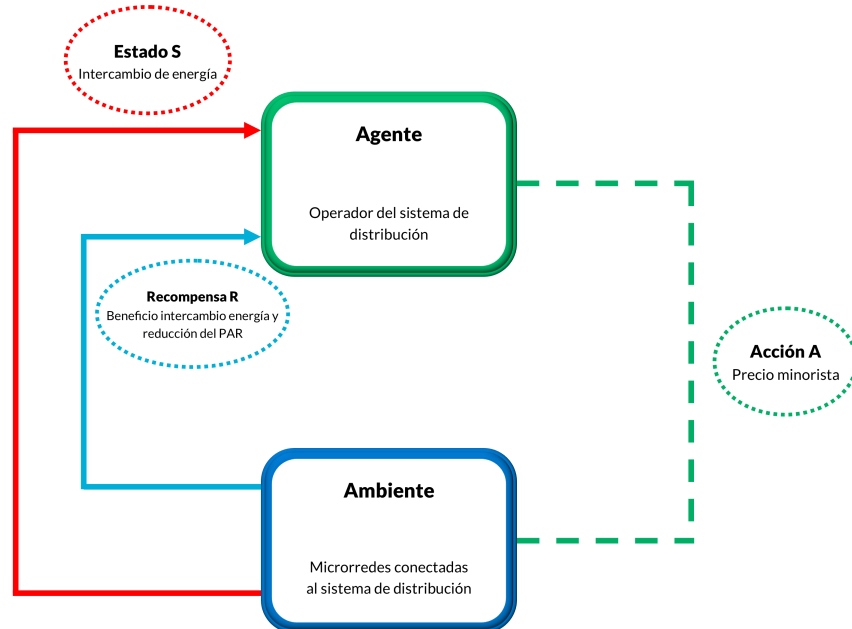


Figura 6. Esquema básico de la técnica Aprendizaje por Refuerzo.

Para este caso de estudio, los elementos de aprendizaje por refuerzo se definen de la siguiente manera:

- Agente: El operador de red que debe definir los precios minoristas de energía horarios.
- Acción: Definición horaria de precio minorista por venta de energía.
- Ambiente: Sistema de distribución con múltiples microrredes (caso de estudio definido en la subsección 2.2)
- Estado: Potencia intercambiada por el sistema de distribución en el nodo de interconexión a la red principal $P_{int}(t)$ (solución de flujo de potencia definido en la subsección 2.2).
- Recompensa: La ganancia proveniente de la venta de energía desde el sistema de distribución a las microrredes y la disminución de la PAR.

A continuación se define la recompensa para la solución del problema planteado.

3.1. Definición de recompensa

La asignación de precios minoristas busca conseguir dos objetivos simultáneos: maximizar la ganancia económica que tiene el OR por la venta de energía y minimizar la PAR. Por esta razón, la recompensa está compuesta de dos términos.

El primer término corresponde a la ganancia G , la cual se calcula como:

$$G(\$_{kWh}, P_{int}) = \sum_{t=0}^{23} \lambda^t \cdot \$_{kWh}(t) \cdot \frac{P_{int}(t)}{profit_{base}} \quad (8)$$

donde $\$_{kWh}$ corresponde al precio seleccionado y P_{int} a la potencia intercambiada por el sistema de distribución en el nodo de interconexión a la red principal para la hora t . Por su parte, el $profit_{base}$ es un valor usado con el fin de escalar la potencia para obtener una ganancia con un rango de valores comparativos con respecto a la PAR, para este trabajo se utilizó un $profit_{base} = 0.01$. El término λ corresponde a un factor de descuento que puede tomar valores entre 0 y 1, el cual es utilizado para ponderar el peso de recompensas futuras. Así, un $\lambda = 0$ solo permitirá considerar recompensas actuales y un $\lambda = 1$ dará importancia alta a las recompensas a largo plazo. Para este trabajo se asumirá un $\lambda = 0.9$.

El segundo término corresponde la PAR, el cual se refiere a la relación entre el valor máximo (pico) y el valor promedio de consumo de potencia para un día de operación. En el contexto del consumo de energía, la PAR indica qué tan alto es el consumo durante las horas pico en comparación con el consumo promedio. Es una medida importante para comprender y gestionar la demanda energética, ya que permite evaluar la variabilidad y la intensidad del consumo en momentos de mayor demanda. Para calcular la PAR, se utiliza la siguiente ecuación:

$$PAR(P_{int}) = \frac{\max(\mathbf{P}_{int})}{\text{mean}(\mathbf{P}_{int})} \quad (9)$$

donde \mathbf{P}_{int} corresponde al vector de las potencias intercambiadas $P_{int}(t)$ para t desde 0 a 23. La función \max calcula el valor máximo (valor pico) del vector y la función mean su promedio. La figura 7 proporciona una representación visual más clara de la PAR, para la cual, se usaron como referencia las potencias intercambiadas por el sistema de distribución con múltiples microrredes.

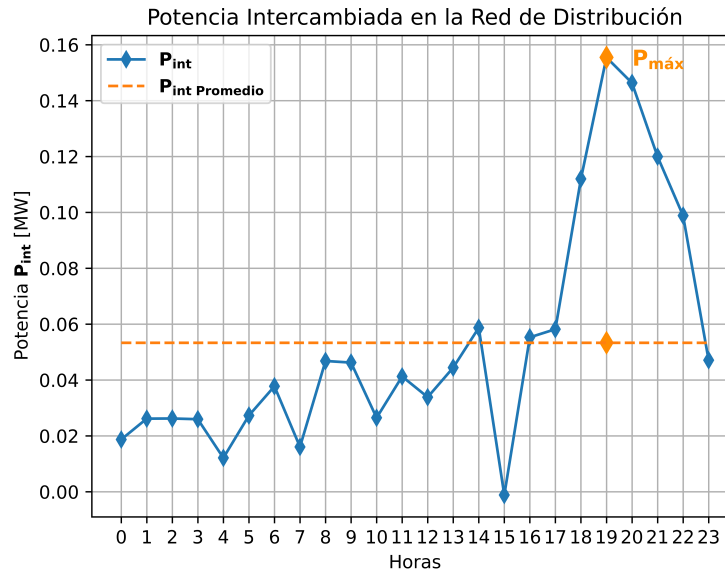


Figura 7. Gráfica con el comportamiento de las potencias intercambiadas.

Finalmente, la ecuación 10 expresa la recompensa para el entrenamiento:

$$R(\$_{kWh}, P_{int}) = \alpha \cdot G - (1 - \alpha) \cdot PAR = \alpha \cdot \left(\sum_{t=0}^{23} \lambda^t \cdot \$_{kWh}(t) \cdot \frac{P_{int}(t)}{profit_{base}} \right) - (1 - \alpha) \cdot \frac{\max(P_{int})}{\text{mean}(P_{int})} \quad (10)$$

En esta ecuación se incluye el parámetro α con valores entre 0 y 1, el cual asigna un peso a cada componente. El valor de este parámetro será analizado en las siguientes secciones.

Es deseable obtener el mayor valor de recompensa R posible. Por esta razón, se incluye un signo negativo para la PAR , pues se busca maximizar el valor de G (mayor ganancia por venta de energía) y minimizar el valor de la PAR (reducción del pico de consumo).

Nótese que la recompensa R depende de los valores de $\$_{kWh}$ y P_{int} . La primera variable es

la acción A tomada por el agente. La segunda variable se obtiene a partir de resolver los flujos de potencia del sistema de distribución una vez las microrredes han definido sus respectivas potencias intercambiadas P_{sys} para el valor de precio determinado. Por otro lado, teniendo en cuenta que la PAR requiere calcular \mathbf{P}_{int} , solo es posible obtener la R para una época compuesta por la solución de un día (24 horas).

3.1.1. Técnica de entrenamiento basada en el método de Monte Carlo. La técnica de entrenamiento basada en el método de Monte Carlo se utiliza para predecir la probabilidad de diferentes resultados en procesos con variables aleatorias. Este método es especialmente útil cuando se trabaja con energías renovables, donde la irradiación solar y la velocidad del viento pueden variar de manera impredecible en un día determinado. En estas simulaciones, se asignan valores aleatorios a cada variable y se ejecuta el modelo para obtener un resultado. Este proceso se repite varias veces con el fin de obtener tendencias que permitan obtener estimaciones realistas de los posibles resultados (Thomas, 2020).

Para este trabajo, se utilizará un método de entrenamiento en el que se generarán datos sintéticos a partir de datos semilla, considerando perfiles de radiación solar, velocidad del viento y carga típicos. Luego de recorrer una gran cantidad de épocas, se promediarán las recompensas de acciones específicas, con el fin de encontrar la mejor política de asignación de precios diaria. Según la ley de los grandes números, cuando se tienen suficientes simulaciones y muestras de recompensa, los resultados obtenidos son cercanos a los mejores valores posibles (Du and Li,

2020).

4. Fase de entrenamiento

Antes de abordar esta fase, se llevó a cabo una etapa esencial que fue la creación de la base de datos utilizada para entrenar el modelo.

4.1. Creación base de datos

Es necesaria la creación de los días sintéticos para los perfiles de irradiación solar, velocidad del viento y de carga. Para este trabajo, estos datos meteorológicos se obtuvieron de históricos de una región en La Guajira (Colombia).

En la figura 8 se muestra el perfil de radiación solar para un día tipo, el cual será usado como "día semilla", es decir, a partir del cual se obtendrán los días sintéticos. Por su parte, la figura 9 presenta el día semilla para la velocidad de viento.

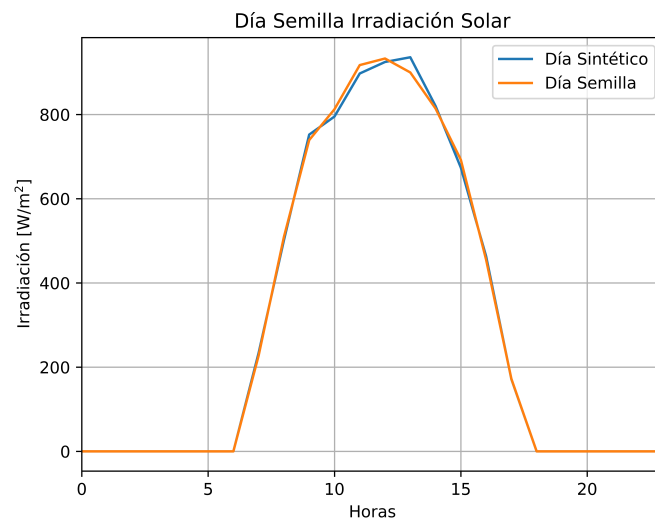


Figura 8. Día semilla y día sintético de irradiación solar.




Figura 9. Día semilla y día sintético de velocidad del viento.

Con el algoritmo 1 se generan datos sintéticos haciendo uso de una distribución normal aleatoria, que permite simular la variabilidad de estos datos meteorológicos. Para la radiación solar se utilizó una media $\mu = 1$ y una desviación estándar $\sigma = 0.036$, mientras que para la velocidad del viento se usó $\mu = 1$ y $\sigma = 0.004$.

Algorithm 1 Algoritmo para generar N_{sint} días sintéticos

```

1: function
2:   Cargar vector semilla  $X_{sem}$ 
3:   Definir un vector vacío  $X_{sint}$ 
4:   for  $i \leftarrow 1$  hasta  $N_{sint}$  do
5:     for  $j \leftarrow 0$  hasta 23 do
6:       Aplicar distribución normal a  $X_{sem}(j)$ 
7:       Almacenar en  $X_{sint}(i, j)$ 
8:     end for
9:   end for
10: end function

```

Finalmente, para generar los perfiles de carga, se utilizó un perfil base que representa la

carga en cada hora del día en valores por unidad. A partir de este perfil base, se calcula la potencia de carga multiplicando la potencia nominal de cada microrred (ver Tabla 1) por la potencia en por unidad correspondiente a cada hora, obteniendo así la potencia en kilovatios (kW).

En la figura 2 se puede observar el comportamiento de la potencia en por unidad generada a partir de la distribución normal aleatoria con $\mu = 1$ y $\sigma = 0.05$.

4.2. Acciones y Estados de entrenamiento

Para la etapa de entrenamiento se utilizan 5 posibles precios expresados en dólares por kilovatio - hora (USD/kWh). Se trabaja con estos valores para limitar la búsqueda y la cantidad de épocas necesarias para obtener un resultado.

Los precios utilizados son los siguientes:

$$[0.027, 0.0285, 0.03, 0.0315, 0.033] \quad (11)$$

Un OR con una política diaria de asignación de precios constante, define durante las 24 horas el mismo valor de costo de energía. El objetivo de entrenar con la técnica de aprendizaje por refuerzo es obtener una política diaria (vector de 24 horas) con diferentes precios en cada hora dentro de los 5 valores posibles.

4.3. Entrenamiento

En el algoritmo 2 se muestra la secuencia lógica para llevar a cabo el entrenamiento y obtener la política de precios minoristas. Previamente, se creó la base de datos formada por una matriz de $24 \times N_d$ (días) en la que en cada elemento de esta matriz se encuentran registrados dos valores, los cuales

son: un valor de precio $\$_{kWh}$ y el respectivo valor de potencia intercambiada P_{int} obtenido a partir de solucionar los flujos de potencia del sistema (ver sección 2.2). La información correspondiente a la irradiación solar, velocidad del viento y carga para estos N_d días se obtuvo generando días sintéticos, como se en la subsección 4.1.

Algorithm 2 Algoritmo de entrenamiento: Método de Monte Carlo para la toma de decisiones del OR

```

1: Cargar la base de datos BD (matriz de  $24 \times N_d$ )
2: Definir número de épocas  $N_e$ 
3: Crear un vector de ceros  $\pi$  de tamaño 24
4: Crear un vector de ceros  $\mathbf{P}_\pi$  de tamaño 24
5: for  $h \leftarrow 0$  hasta 23 do
6:   Crear una matriz de ceros PP de tamaño  $N_e \times 24$ 
7:   Crear vector fila de ceros G de tamaño  $N_e$ 
8:   Crear vector fila de ceros PAR de tamaño  $N_e$ 
9:   Crear vector fila de ceros R de tamaño  $N_e$ 
10:  for  $e \leftarrow 0$  hasta  $N_e$  do
11:    for  $t \leftarrow h$  hasta  $h + 23$  do
12:      if  $t \leq 23$  then
13:        Seleccionar un elemento aleatorio de BD( $t, :$ ) y almacenarlo en PP( $e, t - h$ )
14:      else
15:        Almacenar el precio  $\pi(t - 24)$  y la potencia  $\mathbf{P}_\pi(t - 24)$  en PP( $e, t - h$ )
16:      end if
17:    end for
18:    Calcular la ganancia  $G$  usando la fila PP( $e, :$ ). Almacenarla en G( $e$ )
19:    Calcular la  $PAR$  usando la fila PP( $e, :$ ). Almacenarla en PAR( $e$ )
20:    Calcular la recompensa R( $e$ ) con G( $e$ ) y PAR( $e$ )
21:  end for
22:  Seleccionar  $\max\{\mathbf{R}\}$ . Guardar su posición como  $e_{max}$ .
23:  Extraer PP( $e_{max}, 0$ ). Almacenar  $\$_{kWh}$  en  $\pi(h)$  y  $P_{int}$  en  $\mathbf{P}_\pi(h)$ 
24: end for

```

4.4. Análisis de los parámetros de entrenamiento

A continuación se presenta un barrido del peso α , variando de 0 a 1, en pasos de 0.2 incluyendo el valor de 0.5, con el fin de analizar el comportamiento de la ganancia **G**, la **PAR** y la recompensa

R. Cabe resaltar que se hace el ejercicio con N_e igual a 10.000 épocas. Los resultados se presentan en la figura 10. Esta figura permite observar las siguientes correlaciones entre las variables:

- A medida que α aumenta, la componente de la recompensa $\alpha \cdot \mathbf{G}$ aumenta: Esta correlación es esperada pues al aumentar α se le da más peso a la ganancia \mathbf{G} en la recompensa, lo cual se ve reflejado en el término $\alpha \cdot \mathbf{G}$. Se observa que \mathbf{G} alcanza un valor máximo (aproximadamente 4.10) cuando $\alpha = 0.5$, sin embargo, por la ponderación que agrega α , el valor máximo de $\alpha \cdot \mathbf{G}$ (aproximadamente 4) se obtiene cuando $\alpha = 1$.
- A medida que α aumenta, la componente de la recompensa $(1 - \alpha) \cdot \mathbf{PAR}$ disminuye: Para un $\alpha = 0$ se obtendrá el $(1 - \alpha) \cdot \mathbf{PAR}$ mayor (aproximadamente 2.76), mientras que para $\alpha = 1$, se obtendrá $(1 - \alpha) \cdot \mathbf{PAR} = 0$. Es importante resaltar que en la figura 10 se grafica $(1 - \alpha) \cdot \mathbf{PAR}$ positivo, mientras que la recompensa se construye con este término con signo negativo.
- A medida que α aumenta, la recompensa \mathbf{R} aumenta: Esta correlación se da debido a la suma de los efectos de los ítem anteriores y los valores particulares de este caso de estudio, De nuevo, nótese que en la figura 10 se grafica $(1 - \alpha) \cdot \mathbf{PAR}$ positivo, sin embargo, la expresión de la recompensa en la ecuación 10 se construye usando este término con signo negativo. Así, para un $\alpha = 0$, la recompensa se calcula como $\mathbf{R} = \alpha \cdot \mathbf{G} - (1 - \alpha) \cdot \mathbf{PAR} = 0 \cdot 4.05 - (1 - 0) \cdot 2.76 = -2.76$. Por su parte para un $\alpha = 1$, la recompensa \mathbf{R} se calcula como $\mathbf{R} = \alpha \cdot \mathbf{G} - (1 - \alpha) \cdot \mathbf{PAR} = 1 \cdot 4.10 - (1 - 1) \cdot 2.71 = 4.1$.

Finalmente, para la selección de un α debe considerarse, además del valor de la recompensa

R, un buen balance entre los valores de **G** y **PAR** (graficados en líneas punteadas tenues), evitando valores como $\alpha = 0$ o $\alpha = 1$, que eliminan por completo el peso de estos objetivos en la construcción de la recompensa **R**. Con respecto a los valores totales para recompensa **R**, se observa que se obtuvieron valores positivos para $\alpha \geq 0.5$. Con respecto al balance entre **G** y **PAR**, es deseable tener la mayor **G** posible y la menor **PAR** posible. Esto se obtiene para $\alpha = 0.8$, por lo que este será el valor que se considerará para las demás simulaciones en este trabajo.

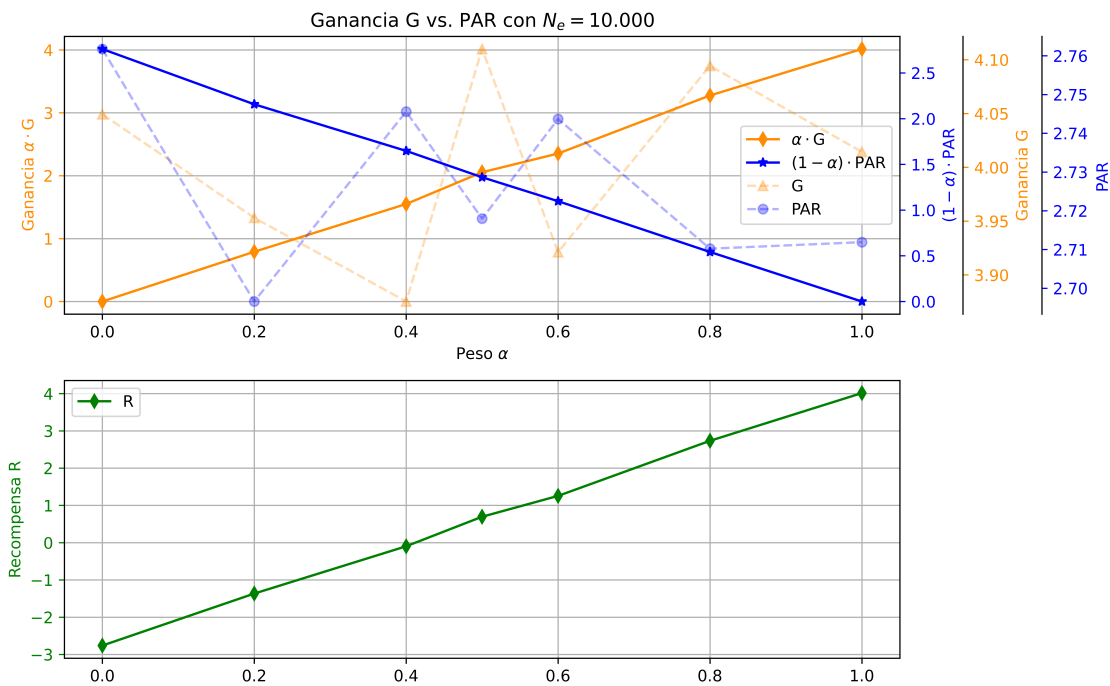


Figura 10. Gráfica de las recompensas tras barrido de pesos α con 10.000 épocas

Una vez seleccionado el peso α , se presenta un análisis de las recompensas variando el número de épocas de entrenamiento N_e . Para estas variables se consideraron los valores $N_e = [100, 500, 1000, 5000, 10000, 25000, 50000, 100000, 200000]$. Los resultados de las recompensas **R** para las políticas obtenidas se muestran en la figura 11.

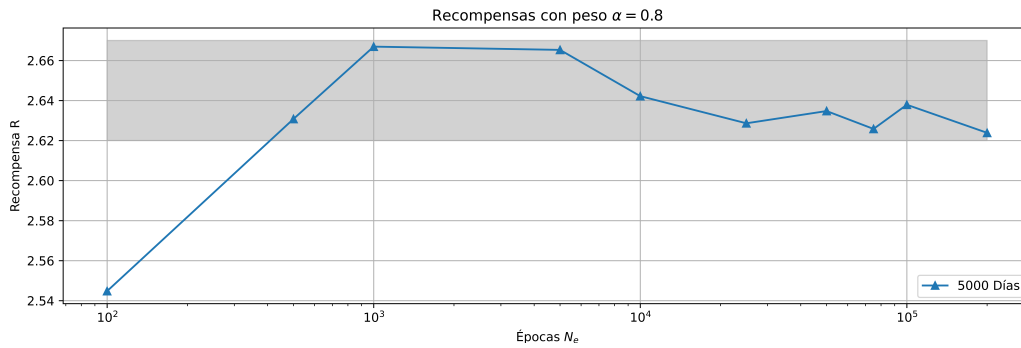


Figura 11. Gráfica de las recompensas tras barrido de épocas

5. Análisis y resultados

La figura 10 registra el comportamiento de la **PAR** con valores que oscilan entre 2.69 y 2.76 aproximadamente, sin embargo, como se explica en la subsección 3.1, el valor ideal para la **PAR** es próximo a la unidad, en este caso, el valor obtenido no es la unidad, no obstante, como se explica en la subsección 4.4, el entrenamiento busca obtener la menor **PAR** posible, esto se evidencia al comparar de forma gráfica la potencia promedio obtenida con los 50 días de validación de la política del entrenamiento π_{Modelo} y un política de precio constante, en este caso la política $\pi_{Precio=0.033}$, como se evidencia en la figura 12.

De igual manera, la figura 11 permite apreciar que a partir de $N_e \geq 1000$ la recompensa se mantiene en la franja de valores resaltada de color gris en la figura. Esta gráfica resulta tras realizar una validación con una base de datos de 50 días diferentes a los 5000 del entrenamiento, y calcular su promedio, con esto se logra concluir que las políticas que se obtienen al entrenar con más de 1000 épocas van a tener una recompensa **R** sin un cambio significativo en su valor, así que no es necesario realizar un entrenamiento con un gran número de épocas para obtener una mejor

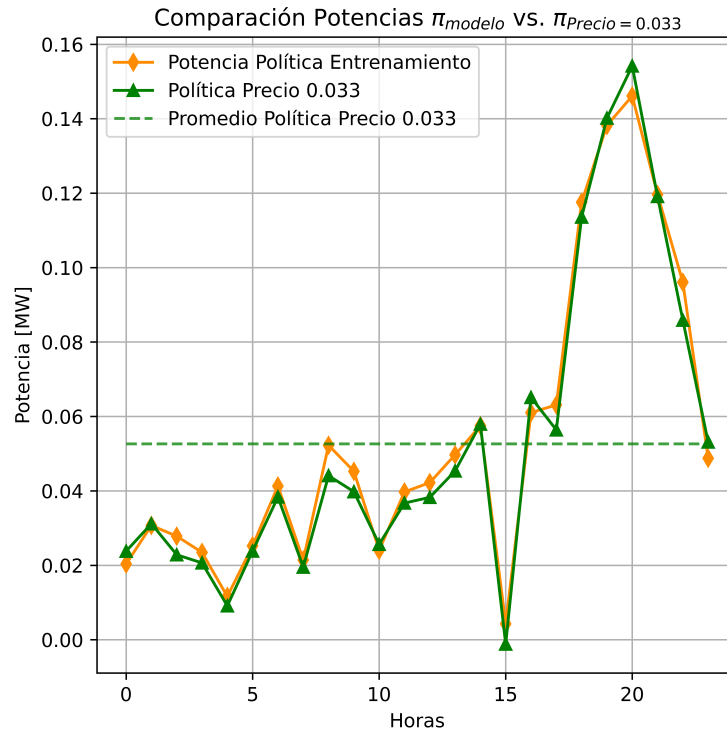


Figura 12. Gráfica comparativa de potencias entre las políticas π_{Modelo} y $\pi_{Precio=0.033}$

recompensa, en este caso de trabajo se utiliza la política obtenida con $N_e = 5000$.

La política de precios que entrega el modelo se registra en la figura 13 y se muestra a continuación, siendo estos precios los que se determinan como la política final que se sugiere al OR para operar.

[0: 0.033, 1: 0.03, 2: 0.0285, 3: 0.0285, 4: 0.0315, 5: 0.0315, 6: 0.0315, 7: 0.03, 8: 0.033, 9: 0.0315, 10: 0.033, 11: 0.033, 12: 0.03, 13: 0.027, 14: 0.0315, 15: 0.027, 16: 0.03, 17: 0.0285, 18: 0.0285, 19: 0.0315, 20: 0.033, 21: 0.033, 22: 0.027, 23: 0.03]




Figura 13. Comparación de las diferentes políticas de precios.

Una vez seleccionada la política, se realiza la validación con la base de datos de N_d igual a 50 días, con la que se evalúan las políticas de precio constante (el mismo precio durante las 24 horas del día), en la tabla 3 se registran los valores de recompensa promedio tras realizar el test.

Tabla 3
Recompensas con diferentes políticas

Política	Recompensa
$\pi_{Precio=0.0285}$	2.457786
$\pi_{Precio=0.03}$	2.556385
$\pi_{Precio=0.0315}$	2.657393
π_{Modelo}	2.665304

Es posible resaltar como la recompensa obtenida con la política de entrenamiento π_{Modelo} , es mejor que las políticas de precio constante, siendo 8.4432% mejor que la política de precio constante $\pi_{Precio=0.0285}$, 4.2606% mejor que la política de precio constante $\pi_{Precio=0.03}$ y finalmente, 0.2976% mejor que la política de precio constante $\pi_{Precio=0.0315}$.

6. Conclusiones

A partir del desarrollo presentado y los resultados obtenidos en el presente trabajo de grado, es posible enunciar la siguiente conclusión general: El uso del aprendizaje por refuerzo para la asignación de precios minoristas sí determinó una política de precios con una mejor recompensa que la política de un precio fijo durante todas las horas del día, como se muestra en la tabla 3.

En paralelo, partiendo de un día semilla para cada uno de los datos meteorológicos y la carga obtenido de una base de datos de La Guajira, se elaboró un algoritmo con el que se pudo crear un conjunto de datos sintéticos, los cuales se usaron para la simulación de cada una de las microrredes, en otras palabras, para el sistema de distribución. Cabe resaltar que cada microrred tenía una configuración particular dando una respuesta diferente a la misma base de datos.

Asimismo, fue posible desarrollar un sistema de distribución compuesto por 4 microrredes, en la que cada microrred realizaba su flujo de potencia en base del precio minorista asignado para una hora del día en específico y sus recursos energéticos. Tras esto la herramienta de PandaPower utilizó para solucionar el flujo de potencia del sistema de distribución y así se obtuvieron las potencias de intercambio con las cuales se realizó el entrenamiento del modelo.

Igualmente se elaboró el algoritmo para la asignación de precios minoristas en el sistema de distribución implementado y descrito en el presente trabajo, este algoritmo tenía la capacidad de cambiar sus parámetros con el fin de ajustarse a las necesidades del proyecto y configurar de la mejor forma la estrategia de aprendizaje por refuerzo, la cual asignó las políticas de precios minoristas.

7. Recomendaciones y trabajo futuro

Se propuso realizar el entrenamiento basado en una base datos obtenida directamente de un sistema de distribución real. Después de realizar el entrenamiento se podría implementar la variación de precios, en esa región acotada del sistema y ver el comportamiento midiendo los beneficios obtenidos, como lo son la ganancia **G** y la **PAR**.

Basándonos en la investigación realizada hasta el momento, se identifican diversas oportunidades para realizar trabajos futuros que amplíen y enriquezcan el alcance del proyecto. A continuación, se presentan algunas recomendaciones para investigaciones futuras:

1. **Ampliar el sistema de microrredes:** Se sugiere ampliar el sistema de microrredes considerado en este trabajo, incluyendo un mayor número de microrredes y aumentando su complejidad. Esto permitirá analizar cómo interactúan y se coordinan entre sí diferentes microrredes en un sistema más grande y robusto. Se podrían explorar nuevas configuraciones de microrredes y considerar la incorporación de elementos adicionales, como bancos de baterías o PCH (Pequeñas Centrales Hidráulicas), para evaluar su impacto en la eficiencia y sostenibilidad del sistema de distribución.
2. **Análisis de variables adicionales:** Se recomienda incorporar variables adicionales en el análisis de las microrredes. Por ejemplo, se podría considerar el estudio de la carga trifásica desbalanceada, que es común en muchos sistemas de distribución eléctrica en la vida real. Esto permitirá evaluar cómo afecta el desequilibrio de carga a la operación y optimización

de las microrredes, así como desarrollar estrategias de gestión de carga más eficientes.

3. **Aplicación a escala regional o nacional:** Una posible dirección para futuras investigaciones es aplicar el enfoque propuesto a una escala mayor, como una región, departamento o incluso a nivel nacional. Esto implicaría considerar un sistema de distribución más complejo y diverso, abordando desafíos adicionales en términos de planificación y coordinación de microrredes. Estos estudios a gran escala podrían proporcionar información valiosa para la toma de decisiones en políticas energéticas a nivel regional o nacional.
4. **Optimización multi-objetivo:** Otra línea de investigación interesante es la optimización multi-objetivo, donde se consideren múltiples objetivos, como la minimización del costo operativo, la maximización del uso de energías renovables y la minimización del impacto ambiental. Esto requeriría el desarrollo de algoritmos y técnicas de optimización más avanzadas para abordar la complejidad de la optimización en problemas multi-objetivo.
5. **Mejoramiento de la base de datos meteorológica:** En este trabajo, se ha creado una base de datos meteorológica a partir de un único registro de La Guajira. Para mejorar el proceso, se sugiere considerar la utilización de más de un día semilla en la creación de la base de datos.

En conclusión, el trabajo de investigación actual sienta las bases para futuras investigaciones en el campo de la asignación de precios minoristas en sistemas de distribución con múltiples microrredes. Las recomendaciones mencionadas ofrecen oportunidades para expandir y mejorar el proyecto, abordando desafíos más complejos y aplicando el enfoque propuesto en un contexto

más amplio. Estos trabajos futuros podrían contribuir significativamente al desarrollo de soluciones energéticas más eficientes y sostenibles a nivel regional o nacional.

Referencias Bibliográficas

Clifford-Power (2023). *Diesel Generator Fuel Consumption Chart*. Clifford Power.

Dayan, P. and Niv, Y. (2008). Reinforcement learning: The good, the bad and the ugly. *Current Opinion in Neurobiology*, 18(2):185–196.

Du, Y. and Li, F. (2020). Intelligent multi-microgrid energy management based on deep neural network and model-free reinforcement learning. *IEEE Transactions on Smart Grid*, 11(2):1066–1076.

Farrokhhabadi, M., Cañizares, C. A., Simpson-Porco, J. W., Nasr, E., Fan, L., Mendoza-Araya, P. A., Tonkoski, R., Tamrakar, U., Hatziargyriou, N., Lagos, D., Wies, R. W., Paolone, M., Liserre, M., Meegahapola, L., Kabalan, M., Hajimiragha, A. H., Peralta, D., Elizondo, M. A., Schneider, K. P., Tuffner, F. K., and Reilly, J. (2020). Microgrid stability definitions, analysis, and examples. *IEEE Transactions on Power Systems*, 35(1):13–29.

Geron, A. (2021). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, 2nd edition.

Goodfellow, I. G., Bengio, Y., and Courville, A. C. (2016). *Deep Learning*. Adaptive Computation and Machine Learning. Massachusetts Institute of Technology, Estados Unidos.

Gonen, T. (2014). *Electric Power Distribution Engineering*. Taylor amp; Francis.

- Hossain, M. A., Pota, H. R., Hossain, M. J., and Blaabjerg, F. (2019). Evolution of microgrids with converter-interfaced generations: Challenges and opportunities. *International Journal of Electrical Power and Energy Systems*, 109:160–186.
- IDEAM (2005). Atlas de radiación solar de Colombia.
- Ilinca, A., McCarthy, E., Chaumel, J.-L., and Réiveau, J.-L. (2003). Wind potential assessment of Quebec province. *Renewable Energy*, 28(12):1881–1897.
- Liu, Y., Yuen, C., Huang, S., Ul Hassan, N., Wang, X., and Xie, S. (2014). Peak-to-average ratio constrained demand-side management with consumer's preference in residential smart grid. *IEEE JOURNAL OF SELECTED TOPICS IN SIGNAL PROCESSING*, 8(6):1084–1097.
- Olivares, D. E., Mehrizi-Sani, A., Etemadi, A. H., Cañizares, C. A., Iravani, R., Kazerani, M., Hajimiragha, A. H., Gomis-Bellmunt, O., Saadifard, M., Palma-Behnke, R., Jiménez-Estévez, G. A., and Hatziargyriou, N. D. (2014). Trends in microgrid control. *IEEE Trans. Smart Grid*, 5(4):1905–1919.
- Short, T. A. (2014). *Electric Power Distribution Handbook*. CRC Press, Taylor and Francis Group.
- Sui, B., Wu, H., Wang, M., Zhu, J., Yin, H., Ma, Y., and Li, T. (2022). Research on pricing model of electricity retail package in spot market. *2022 4th International Academic Exchange Conference on Science and Technology Innovation (IAECST)*.
- Thomas, G. (2020). Markov decision processes. Stanford University.

Vergara, P. P., Rey, J. M., Osma, G. A., and Ordoñez, G. (2014). Evaluación del potencial solar y eólico del campus central de la universidad industrial de santander y la ciudad de bucaramanga, colombia. *UIS Ingenierías*, 13(2):49–57.

Willis, H. L. (2004). *Power Distribution Planning Reference Book*. CRC Press, 1 edition.