



Universidad Nacional
SAN LUIS GONZAGA



Atribución-NoComercial-SinDerivadas 4.0 Internacional

Esta licencia es la más restrictiva de las seis licencias principales Creative Commons, permitiendo a otras solo descargar sus obras y compartirlas con otras siempre y cuando den crédito, pero no pueden cambiarlas de forma alguna ni usarlas de forma comercial.

<http://creativecommons.org/licenses/by-nc-nd/4.0>



Recibo de pago N° 786224

Visto el Informe N° 323-2024-PIEO-UI-FIMEE-UNSLG, emitido la operaria del sistema de antiplagio se emite la siguiente constancia:

N° 305-2024

CONSTANCIA

El que suscribe, director de la Unidad de Investigación de la Facultad de Ingeniería Mecánica Eléctrica y Electrónica, hace constar que se ha realizado el análisis con el software de verificación de similitud de la **Tesis** cuyo título es:

**“OPTIMIZACIÓN DE LA TASA DE UTILIZACIÓN DE ENERGÍAS RENOVABLES
CON UN CONTROL PREDICTIVO BASADO EN MODELOS”**

Presentado por:

CHANGA GONZALES, VICTOR HUGO

BACHILLER de la Facultad INGENIERÍA MECÁNICA ELÉCTRICA Y ELECTRÓNICA – Escuela Profesional de INGENIERÍA MECÁNICA ELÉCTRICA. El resultado obtenido es un porcentaje de UNO POR CIENTO (1%), por el cual se le otorga el calificativo de:

APROBADO

Se adjunta al presente, el reporte de evaluación con el software de verificación de originalidad.

Ica, 19 de Diciembre del 2024

UNIVERSIDAD NACIONAL "SAN LUIS GONZAGA"
FACULTAD DE INGENIERÍA MECÁNICA ELÉCTRICA Y ELECTRÓNICA
UNIDAD DE INVESTIGACIÓN

Dr. José Luis Donayre Pasache
DIRECTOR DE UNIDAD

UNIVERSIDAD NACIONAL "SAN LUIS GONZAGA"
VICERRECTORADO DE INVESTIGACIÓN
Facultad de Ingeniería Mecánica Eléctrica y Electrónica



Optimización de la tasa de utilización de energías renovables con un control predictivo basado en modelos

Línea de investigación

Ciencias naturales, ingeniería y tecnologías sostenibles

INFORME FINAL DE TESIS

AUTOR:

CHANGA GONZALEZ VICTOR HUGO

Ica, Perú

2024

Dedicatoria

A mi padre, cuya ausencia física nunca ha logrado silenciar su presencia en mi vida. Aunque no estés aquí, tu ejemplo, amor y enseñanzas siguen siendo mi guía constante. Este logro es también tuyo.

Agradecimientos

Quiero expresar mi más sincero agradecimiento a todas las personas que han sido clave en este recorrido académico.

A mi madre, por su amor incondicional, sacrificio y por ser mi fuente de motivación constante. Tus palabras de aliento y tu fe en mí me han dado la fuerza para seguir adelante.

A los docentes ingenieros, quienes no solo compartieron su conocimiento, sino también su pasión por la ingeniería.

Índice

Dedicatoria.....	ii
Agradecimientos	iii
Índice.....	iv
Índice de tablas.....	vi
Índice de figuras.....	vii
Resumen.....	viii
Abstract.....	ix
I. Introducción.....	1
1.1. Situación problemática.....	1
1.1.1. Problema general.....	1
1.1.2. Problemas específicos	1
1.2. Antecedente de la investigación.....	1
1.2.1. Antecedentes internacionales	1
1.2.2. Antecedente nacional	2
1.2.3. Antecedente local	2
1.3. Justificación e importancia de la investigación.....	3
1.3.1. Justificación.....	3
1.3.2. Importancia.....	3
1.4. Objetivos de la investigación	4
1.4.1. Objetivo general	4
1.4.2. Objetivos específicos.....	4
1.5. Hipótesis de la investigación.....	4
1.5.1. Hipótesis general	4
1.5.2. Hipótesis específicas	4
1.6. Contenido de la investigación	4
II. Estrategia metodológica	5
2.1. Tipo, nivel y diseño de la investigación.....	5
2.1.1. Tipo de la investigación	5
2.1.2. Nivel de la investigación	5
2.1.3. Diseño de la investigación.....	5
2.2. Población y muestra.....	5
2.3. Análisis de las energías renovables.....	5

2.3.1. Análisis de microrredes	6
2.3.2. Análisis de MPC.....	9
2.4. Modelado de sistemas y formulación de problemas	11
2.4.1. Modelado de carga y RES	12
2.5. Sistema de almacenamiento de energía.....	13
2.5.1. Balance de potencia.....	13
2.5.2. Modelado del sistema.....	14
2.6. Propuesta de control predictivo distribuido	14
2.7. Coeficiente de compartición de potencia de la microrred.....	15
2.8. Potencia prestada y compartida.....	16
2.8.1. Energía en ESS.....	16
2.9. Optimización de potencia de carga	17
2.9.1. Energía en el sistema de almacenamiento de energía (ESS).....	17
2.9.2. Potencia prestada y compartida.....	18
2.9.3. Potencia de batería	19
2.9.4. Modelo dinámico.....	19
2.9.5. Potencia de carga óptima.....	20
2.10. Potencia de generador controlada	20
2.10.1. Algoritmo propuesto	20
III. Resultados	22
3.1. Presentación e interpretación de los resultados.....	22
3.2. Contrastación de hipótesis	24
3.2.1. Hipótesis específicas	24
3.2.2. Hipótesis general	24
IV. Discusión	25
V. Conclusiones	26
VI. Recomendaciones	27
VII. Referencias bibliográficas	28

Índice de tablas

Tabla I: Nombres y descripciones de variables.....	11
--	----

Índice de figuras

Figura N°1: Esquema típico de microrred [9].....	7
Figura N°2: Arquitectura de control centralizado [9]	7
Figura N°3: Arquitectura de control descentralizada [9]	8
Figura N°4: Arquitectura de control distribuido [9].....	8
Figura N°5: Niveles de control jerárquico [9].....	9
Figura N°6: Esquema de control MPC [9].....	10
Figura N°7: Potencia de carga optimizada.....	22
Figura N°8: Proporción Optimizada de Utilización de Energía Renovable.....	22
Figura N°9: Energía Optimizada y No Optimizada en ESS.....	23

RESUMEN

El objetivo principal de esta investigación es mejorar la tasa de utilización de energías renovables mediante la implementación de un control predictivo basado en modelos (MPC). El estudio se centra en una red de microrredes, donde cada una posee fuentes de energía renovable y sistemas de almacenamiento. Se propone un algoritmo de optimización que permite maximizar el uso de energía renovable, reduciendo la dependencia de generadores no renovables.

La estrategia metodológica utiliza simulaciones en una red de tres microrredes, aplicando un modelo de control distribuido que ajusta la generación y almacenamiento de energía en tiempo real. El enfoque permite gestionar la incertidumbre de las fuentes renovables y optimizar el uso de los recursos energéticos.

Los resultados muestran que el MPC mejora significativamente la utilización de energías renovables, aumentando la eficiencia de los sistemas de almacenamiento y prolongando su vida útil. Además, el modelo propuesto asegura que el sistema pueda operar de manera óptima incluso durante variaciones en la demanda energética.

En conclusión, el control predictivo basado en modelos ofrece una solución eficiente para maximizar el uso de energías renovables, contribuyendo a la sostenibilidad energética y reduciendo el impacto ambiental.

Palabras clave: energías renovables, control predictivo, microrredes, sostenibilidad, eficiencia energética, reducción de impacto ambiental.

ABSTRACT

The main objective of this research is to improve the utilization rate of renewable energies through the implementation of model predictive control (MPC). The study focuses on a network of microgrids, each equipped with renewable energy sources and storage systems. An optimization algorithm is proposed to maximize the use of renewable energy, reducing reliance on non-renewable generators.

The methodological strategy uses simulations in a network of three microgrids, applying a distributed control model that adjusts energy generation and storage in real-time. The approach allows for managing uncertainty in renewable sources and optimizing the use of energy resources. The results show that MPC significantly improves the use of renewable energies, increasing the efficiency of storage systems and prolonging their lifespan. Additionally, the proposed model ensures the system operates optimally even during energy demand variations.

In conclusion, model predictive control offers an efficient solution to maximize the use of renewable energies, contributing to energy sustainability and reducing environmental impact.

Keywords: renewable energies, predictive control, microgrids, sustainability, energy efficiency, environmental impact reduction.

I. INTRODUCCIÓN

1.1. Situación problemática.

En Perú, la realidad energética enfrenta desafíos significativos en cuanto a la integración y optimización de energías renovables. Aunque el país posee un notable potencial en recursos renovables, como la energía solar, eólica e hidroeléctrica, la tasa de utilización efectiva de estas fuentes es aún limitada, lo que compromete la sostenibilidad y eficiencia del sistema energético nacional. Según el Ministerio de Energía y Minas, para 2024, solo un 7% de la matriz energética nacional proviene de fuentes renovables no convencionales, un porcentaje que, si bien ha crecido en la última década, todavía resulta insuficiente para enfrentar las metas climáticas y energéticas establecidas por el gobierno. El principal obstáculo en la integración de energías renovables en la matriz energética peruana reside en la variabilidad y naturaleza intermitente de estas fuentes. La energía solar y eólica, en particular, presentan fluctuaciones considerables en función de las condiciones meteorológicas y horarios específicos, lo que dificulta su integración estable en la red eléctrica. En muchas ocasiones, esto provoca una dependencia excesiva de las plantas térmicas convencionales, que actúan como respaldo para suplir la energía cuando las fuentes renovables no pueden cubrir la demanda. En consecuencia, se reduce la tasa de utilización de la energía renovable disponible, desaprovechando una cantidad significativa de potencial energético limpio. Otro desafío relevante es la limitada capacidad de almacenamiento energético en el país. La falta de infraestructura de almacenamiento a gran escala, como baterías o sistemas de almacenamiento hidráulico, impide la acumulación de energía generada en momentos de alta producción solar o eólica, dificultando su aprovechamiento durante las horas de mayor demanda. Esto impacta negativamente en la eficiencia general del sistema, ya que la falta de mecanismos de almacenamiento adecuados obliga a las plantas de energía renovable a operar de manera subóptima. El sistema de transmisión y distribución también enfrenta limitaciones que agravan la situación. Las redes eléctricas en algunas regiones peruanas, especialmente en áreas rurales y de difícil acceso, carecen de la capacidad adecuada para integrar grandes volúmenes de energía renovable de forma eficiente. Este déficit de infraestructura impide que la energía limpia generada en plantas renovables llegue de manera efectiva a los centros de consumo, reduciendo aún más la tasa de utilización de estas fuentes en la matriz energética nacional. Ante esta problemática, surge la necesidad de adoptar estrategias de control avanzadas, como el control predictivo basado en modelos (Model predictive control – MPC, en inglés), que permite anticipar las fluctuaciones en la generación de energías renovables y ajusta de manera proactiva la operación del sistema eléctrico. A través de un MPC, se puede optimizar la asignación de

recursos energéticos y mejorar la estabilidad del sistema, lo que permitiría incrementar la participación efectiva de las energías renovables en la matriz energética peruana. Actualmente, la implementación de este tipo de control predictivo es una herramienta crucial para enfrentar los desafíos mencionados, especialmente considerando que el objetivo del país es alcanzar un 20% de generación de energías renovables no convencionales para el año 2030, una meta ambiciosa que requiere un enfoque técnico y operativo más avanzado. El uso de un control predictivo basado en modelos no solo aborda la gestión de la intermitencia de las energías renovables, sino que también mejora la estabilidad del sistema en situaciones de alta demanda o baja generación.

1.1.1. Problema general.

La presente investigación, responde a la línea de investigación de Ciencias Naturales, Ingeniería y Tecnologías sostenibles; y se investiga respecto al siguiente “problema general: “¿Cómo se optimizará la tasa de utilización de energías renovables si se emplea el control predictivo basado en modelos?”.

1.1.2. Problemas específicos.

“Y como problemas específicos, se ha planteado:

PE1:

¿Cómo se optimizará el uso de la fuente de energía renovables en una red de subsistemas de microrred?

PE2:

¿Como se determinará el control predictivo basado en modelos para establecer el coeficiente de reparto de energía en el sistema de almacenamiento de energía?

1.2. Antecedentes de la investigación.

1.2.1. Antecedentes internacionales.

En el año 2023, Birunda y Narmadha, [1] tuvieron como objetivo controlar los sistemas híbridos de energía renovable para la gestión de la energía. Los sistemas consisten en paneles fotovoltaicos, generadores diésel, sistemas eólicos con convertidor elevador DC-DC e inversores. Propusieron el control predictivo basado en modelos (Model predictive control – MPC, en inglés) para la operación de tiempo de resolución de problemas para abordar este problema y compensar el error de predicción. Construyeron un modelo de simulación utilizando el entorno MATLAB/Simulink para confirmar la eficacia del modelo de técnica MPC.

En el año 2024, Lin, et al. [2] Tuvieron como objetivo mejorar la escalabilidad de las soluciones de control óptimas para las operaciones de redes inteligentes mediante la comparación del control predictivo basado en modelos (Model predictive control – MPC, en inglés) y aprendizaje por refuerzo con respecto a sus requisitos y rendimiento de control. Aprovecharon el marco de simulación CityLearn para implementar y comparar

soluciones de control alternativas basadas MPC y aprendizaje por refuerzo RL para la gestión energética de microrredes. Además del rendimiento de control del ahorro de costes y la reducción de carbono, también se examinaron otros factores como la robustez y la transferibilidad. Si bien ambos métodos lograron resultados prometedores, MPC tuvo un rendimiento ligeramente mejor y pudo transferirse sin problemas.

En el año 2023, Kumar y Bae [3] Propusieron un sistema coordinado de gestión dinámica de la energía para microrredes basadas en energías renovables (PMS). Utilizaron una metodología de control predictivo de modelos para el control de ambas capas. La funcionalidad del PMS propuesto se verifica en experimentos de hardware en lazo en diferentes condiciones de funcionamiento. Finalmente mostraron que el rendimiento dinámico de los PMS con el método propuesto es más efectivo en comparación con el método convencional.

En el 2023, Gao, et al. [4] Utilizaron un modelo de predicción híbrido a largo y corto plazo en el framework del control predictivo basado en modelos (Model predictive control – MPC, en inglés). Los resultados muestran que, en comparación con la lógica de control de línea de base actualmente utilizada, el marco de MPC propuesto con predicciones híbridas puede mejorar el índice de seguridad de la batería en un 81.6%, mientras que el índice de operación continua de energía combinada y calor también puede mejorar en un 36.4%.

En el 2023, Thaler, et al., [5] desarrollaron una novedosa estrategia de modelo de control predictivo basado en modelos para una microrred renovable con almacenamiento estacional de hidrógeno. Para permitir el funcionamiento estacional, se proporcionan incentivos para los cambios de energía a largo plazo asignando un valor de coste a la carga de almacenamiento y añadiéndola a la función objetivo de optimización. Con solo un 6% de sobredimensionamiento en comparación con el diseño óptimo del sistema, la estrategia logró suministrar suficiente energía para satisfacer toda la demanda mientras logra una producción y un consumo de hidrógenos equilibrados durante todo el año.

1.2.2. Antecedente nacional.

En el 2019, Benites [6] Realizó un diseño y la simulación de un sistema de control predictivo basado en modelos (Model predictive control – MPC, en inglés) aplicado a un sistema de bombeo solar fotovoltaico, para zonas o poblados alejados de los lugares de servicio de agua y de electricidad, conformando un sistema autónomo. Consideró que uno de los objetivos fundamentales es el control de nivel del tanque de almacenamiento del sistema de bombeo fotovoltaico, usando para ello el MPC, que comparado con la respuesta de un controlador PI, teniendo una respuesta óptima.

1.2.3. Antecedente local.

En el 2021, Andia [7] El trabajo de investigación desarrollado, tiene como interés fundamental el modelado de un control predictivo basado en modelos (Model predictive control – MPC, en inglés) y asociado a un control neurodifuso (CND), con el objeto de optimizar la gestión energética en microrredes eléctricas con fuentes renovables. Se concluye que, el control PMC, logra aprovechar óptimamente los recursos energéticos disponibles y; en cuanto al control Neurodifuso, la variante 3 arroja mejores resultados, aumentando la sostenibilidad del sistema. Para la obtención de los cálculos y simulaciones utilizaron los softwares de Matlab y Simulink.

1.3. Justificación e importancia de la investigación.

1.3.1. Justificación.

La investigación se justifica socialmente, ofrece beneficios tangibles para la sociedad, mejorando la salud pública, promoviendo la sostenibilidad ambiental, fortaleciendo la economía y garantizando un acceso más justo y seguro a la energía; económicamente, mejora la eficiencia energética, reduce costos operativos y ambientales, atrae inversiones y fomenta el desarrollo económico y la estabilidad del mercado energético; teóricamente, se basa en una amplia gama de teorías y conceptos que abarcan desde el control de sistemas dinámicos y la optimización matemática hasta la sostenibilidad y la resiliencia energética; técnicamente, mejora la estabilidad y eficiencia del sistema eléctrico, reduce costos operativos y aprovecha los avances tecnológicos en TIC; prácticamente, se basa en los beneficios tangibles que ofrece en términos de eficiencia operativa, reducción de costos, mejora de la fiabilidad del suministro eléctrico, facilidad de implementación, y contribución a objetivos de sostenibilidad, y; ambientalmente por su capacidad para reducir las emisiones de GEI, disminuir la contaminación del aire, preservar recursos naturales, reducir la huella ecológica, promover la energía sostenible, aumentar la resiliencia ambiental, proteger la biodiversidad y apoyar políticas ambientales.

1.3.2. Importancia.

Como se ha señalado previamente, la importancia de la propuesta de investigación se enfoca en la optimización del rendimiento de las redes eléctricas a través de la maximización y optimización de la utilización de fuentes de energía renovable (FERs). Al lograr una mejor utilización de las FERs disponibles, se contribuye a un sistema energético más eficiente y sostenible, manteniendo al mismo tiempo un equilibrio adecuado entre la oferta y la demanda de energía. El aporte de la propuesta de investigación a nivel práctico se ciñe en la formulación de una propuesta novedosa destinada a mejorar la eficiencia de la utilización de (FER) en redes eléctricas. Esta propuesta aborda desafíos significativos y demuestra resultados alentadores en simulaciones. Finalmente, se busca la optimización en el rendimiento de las redes

eléctricas al maximizar y optimizar la integración de fuentes de energía renovable. Esto se logra mediante la implementación de un esquema de control predictivo cooperativo distribuido, donde cada subsistema de microrred está compuesto por una carga con capacidad de control, un sistema de almacenamiento de energía y un generador no renovable controlable

1.4. Objetivos de la investigación.

1.4.1. Objetivo general.

Se establece como objetivo general: “Mejorar la optimización de la tasa de utilización de energías renovables empleando el control predictivo basado en modelos”.

1.4.2. Objetivos específicos.

En concordancia con el problema identificado, se tiene los siguientes objetivos específicos:

OE1:

Desarrollar el modelado de una red de subsistemas de microrred para optimizar la utilización de la fuente de energía renovables.

OE2:

Simular el control predictivo basado en modelos para establecer el coeficiente de reparto de energía en el sistema de almacenamiento de energía.

1.5. Hipótesis de la investigación.

1.5.1. Hipótesis general.

Se presenta como hipótesis general: “Con el control predictivo basado en modelos se optimiza la tasa de utilización de energías renovables”.

1.5.2. Hipótesis específicas.

A partir de ello, se plantean las siguientes hipótesis específicas:

HE1:

Con el modelado de una red de subsistemas de microrred se mejora la utilización de la fuente de energía renovables.

HE2:

Con el control predictivo basado en modelos se establece el coeficiente de reparto de energía en el sistema de almacenamiento de energía.

1.6. Contenido de la investigación.

Para una mejor comprensión en el capítulo II, se explica la metodología empleada en la investigación con base al sistema de posicionamiento, implementación del sistema, estructuración del algoritmo híbrido. Siguiendo esta estructura, en el capítulo III, se detallan los resultados derivados de los cálculos y simulaciones. Asimismo, en el capítulo IV, se analizan en profundidad los resultados de la investigación. Respecto al capítulo V, se presentan las conclusiones de la tesis, seguidas por las recomendaciones para futuras

investigaciones en el capítulo VI. Para concluir, en el capítulo VII, las referencias bibliográficas, que se han citado en esta investigación.

II. ESTRATEGIA METODOLÓGICA

2.1. Tipo, nivel y diseño de investigación.

2.1.1. Tipo de la investigación.

Por su propósito el tipo de la investigación es aplicada tecnológica.

2.1.2. Nivel de la investigación.

El nivel de la investigación según su relación de causalidad califica como un estudio explicativo.

2.1.3. Diseño de la investigación.

El diseño de la investigación cumple las condiciones metodológicas de un diseño experimental, debido a que el investigador determina como se desarrollará el experimento, en razón, que de definan las variables observadas, la relación entre ellas y su medición, finalmente analizando la información se obtiene:

- Variable dependiente: Control predictivo basado en modelos.
- Variable independiente: Optimización de la tasa de utilización de energías renovables.

2.2. Población y muestra.

En la investigación se procedió a identificar la unidad de análisis que también es la unidad muestral, en este caso, es la optimización de la tasa de utilización de energías renovables, existentes en el estudio.

2.3. Análisis de la energías renovables.

Las fuentes de energía renovable están ocupando cada vez un mayor porcentaje de nuestra red eléctrica. No obstante, los generadores distribuidos renovables presentan nuevos desafíos que deben ser superados mientras se integra esta tecnología emergente en nuestra red existente sin afectar el rendimiento en el extremo del cliente. Esta es una tarea compleja y de gran envergadura, con consecuencias reales y costosas si no se realiza de manera correcta. La complejidad proviene principalmente de la naturaleza variable de las fuentes de energía renovable (Renewable energy sources – RES, en inglés), y se maneja mejor maximizando la utilización de la energía renovable tan pronto como se genera. Por lo tanto, los algoritmos computacionalmente eficientes para controlar la utilización de estas fuentes de energía renovable son de suma importancia para una transición suave hacia una era de recursos renovables.

Cada microrred (MR) opera de manera independiente, pero puede utilizar la información de otras microrredes en el sistema para determinar el conjunto óptimo de acciones a tomar en cualquier momento dado. Esto es importante porque la energía renovable tiene una producción variable y, por lo tanto, debe ser utilizada o almacenada inmediatamente después de ser generada.

El primer objetivo de este documento será desarrollar un algoritmo para determinar el porcentaje del total de energía que debe compartirse entre las microrredes. Este término será representado por la variable α_i , donde $0 \leq \alpha_i \leq 1$, que es el porcentaje de la energía total que la i-ésima microrred está absorbiendo.

El segundo concepto que este documento introducirá es la energía proporcionada a la i-ésima microrred por el i-ésimo generador controlable, representado por la variable P_i^C . Aunque este documento se enfoca en maximizar el uso de energías renovables, en el caso de que las energías renovables no sean suficientes para satisfacer la carga, los generadores no renovables deben estar disponibles para satisfacer la demanda del cliente.

El tercer concepto introducido en este documento es un algoritmo más eficiente desde el punto de vista computacional que aprovecha las ecuaciones matriciales y la previsión de carga. Esto reducirá el número total de pasos necesarios para que el algoritmo maximice la relación de utilización de la energía, definida en la Ec. (1), y permitirá calcular una estrategia de optimización en línea o en tiempo real.

$$REUR = \frac{\sum_{i=1}^N P_i^{REU}(k)}{\sum_{i=1}^N P_i^L(k)} \quad (1)$$

Donde $P_i^{REU}(k)$ es la cantidad total de energía renovable utilizada por la i-ésima microrred en el tiempo k, $P_i^L(k)$ es la potencia de carga en la i-ésima microrred en el tiempo k, y N es el número total de microrredes en el sistema.


Asumiendo acceso inicial a los datos pronosticados de carga y de potencia de las fuentes de energía renovable (renewable energy sources – RES, en inglés), el plan es dividir el problema de maximizar la utilización de energía renovable en tres problemas diferentes, los cuales se describen a continuación.

1. Optimización del coeficiente de reparto de potencia $\alpha_i \forall i$: Esto representa el porcentaje de la potencia total excedente que recibe cada microrred. Se asume que toda la potencia excedente se distribuye y que las microrredes que generan exceso de potencia no toman prestada energía de otras microrredes.
2. Programación de la coordinación de la potencia computacional: Esto determina la potencia que entra en el sistema de almacenamiento de energía (SAE) de cada microrred en el tiempo k, lo que nos permite determinar si el subsistema está cargando o descargando y maximizar el uso de las FER.
3. Cálculo de la potencia de carga óptima, $P_{L,opt}$: Esta potencia se implementará utilizando métodos de control de carga.

A lo largo de todos estos pasos, se crearán ecuaciones matriciales para simplificar el algoritmo y reducir la complejidad computacional.

2.3.1. Análisis de microrredes. Una microrred se define, según el Grupo de Intercambio de Microrredes del Departamento de Energía de los Estados Unidos, como un grupo de

cargas interconectadas y recursos energéticos distribuidos (DERs) dentro de límites eléctricos claramente definidos que actúan como una única entidad controlable con respecto a la red [8]. Esto significa que puede verse como una red eléctrica local que es capaz de actuar de forma independiente (modo aislado) o de trabajar en conjunto con otras microrredes y la red principal (conectada a la red). Un ejemplo de tal sistema



se muestra en la figura a continuación.

Figura N°1: Esquema típico de microrred [9].

Cada microrred está típicamente compuesta por una carga, un sistema de almacenamiento de energía y un generador controlable. Para los propósitos de este documento, cada MG se define como un sistema con un sistema de almacenamiento de energía (ESS) (como baterías, celdas de combustible y volantes de inercia), una fuente de energía renovable (RES) (como solar, eólica o hidroeléctrica), y una carga que debe ser satisfecha.

Hay tres formas principales en las que el sistema de gestión de energía de la microrred (MEMS) puede controlar la red.

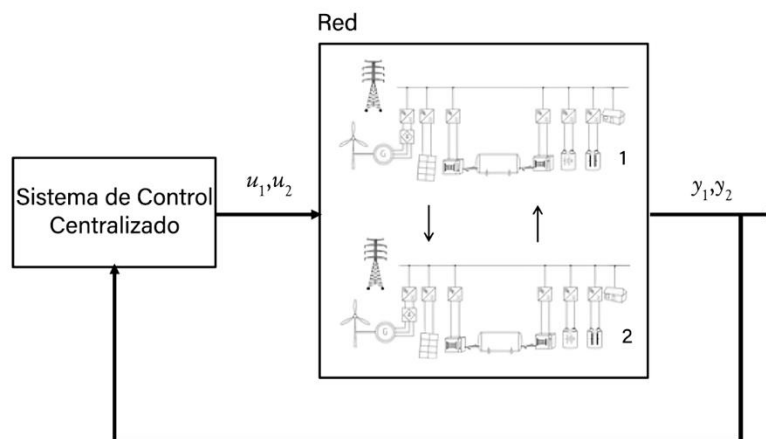


Figura N°2: Arquitectura de control centralizado [9].

1. Se utiliza un método en el que un único agregador controla todos los sistemas, conocido como esquema de control centralizado, como se muestra en la figura N°2. Este método puede volverse muy intensivo computacionalmente a medida que aumenta el tamaño de la red.
2. Se utiliza un método en el que las cargas y los generadores distribuidos se dividen en subsistemas conocidos como micro-redes, donde cada micro-red tiene un agregador local que maximiza las restricciones locales, conocido como control descentralizado, como se muestra en la figura N°3. Esto reduce la carga computacional al tratar con sistemas grandes, pero cada microrred no puede acceder a ninguna información sobre las microrredes vecinas, lo que puede llevar a que el comportamiento de toda la red sea subóptimo.
3. Se utiliza un esquema de control distribuido, como se muestra en la figura N°4, que es similar al segundo método excepto que las microrredes en el subsistema pueden acceder a información parcial o completa sobre las demás. Con esto, cada subsistema de microrred puede trabajar cooperativamente para maximizar una función de costo global, mejorando así el rendimiento del sistema.

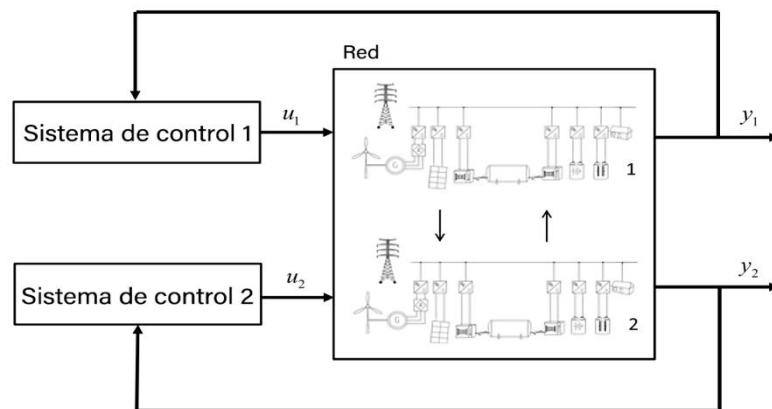


Figura N°3: Arquitectura de control descentralizada [9].

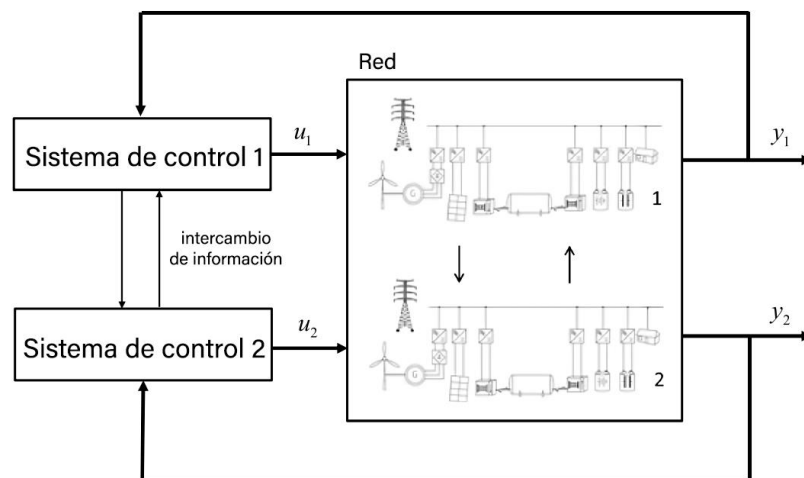


Figura N°4: Arquitectura de control distribuido [9].

En general, la tendencia de pasar de una red eléctrica totalmente centralizada a una red eléctrica más distribuida, así como la dificultad para controlar los recursos de energía renovable, hacen de las microrredes, y especialmente el control de la energía renovable en microrredes, un tema importante para esta tesis.

Independientemente de la arquitectura de control, normalmente se utiliza una estructura de control jerárquica para todas las microrredes. En este sistema existe un nivel primario, secundario y terciario donde se realizan diferentes optimizaciones en función de diferentes escalas de tiempo. La primaria es la escala de tiempo más corta, mientras que el nivel terciario es la escala de tiempo más larga. Un resumen de estos niveles se muestra en la figura N°5.

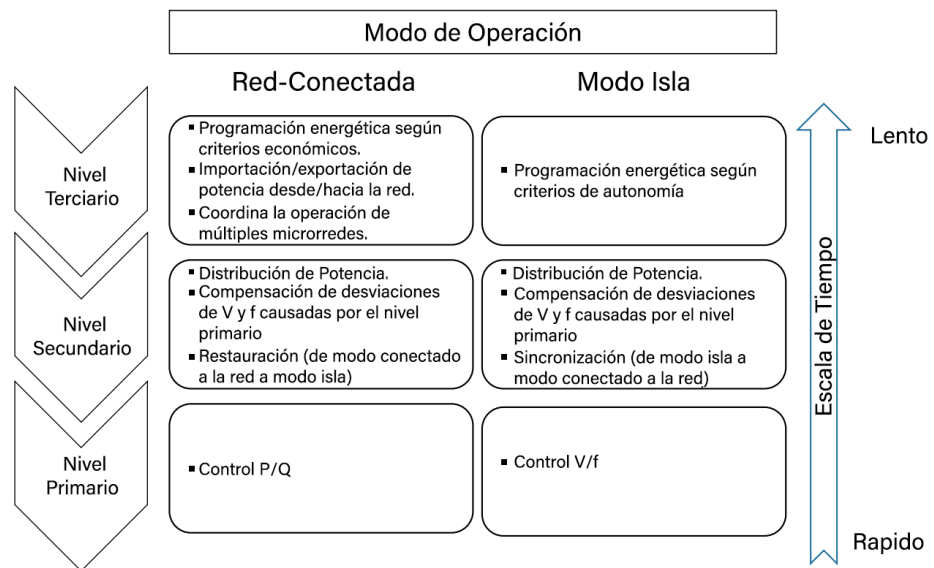


Figura N°5: Niveles de control jerárquico [9].

El principal punto de interés de esta tesis será el desarrollo de un sistema de gestión energética (EMS), que incluye una combinación de niveles secundarios y terciarios.

2.3.2. Análisis de MPC. El control predictivo basado en modelo (MPC) es un método para controlar y optimizar un proceso manteniéndose dentro de ciertos límites predefinidos. Una ventaja significativa de este método es que tiene en cuenta los estados futuros del sistema que está controlando, lo cual lo hace ideal para sistemas de energía donde es común disponer de datos de pronóstico que predicen los valores de carga y de potencia renovable disponible en momentos específicos.

Para utilizar MPC, debe estar disponible un conjunto de ecuaciones en la siguiente forma:

$$x(k + 1) = A(k)x(k) + B(k)u(k) \quad (2)$$

$$y(k) = C(k)x(k) + D(k)u(k) \quad (3)$$

Donde $x(k)$ es el estado, $y(k)$ es la salida y $u(k)$ es la señal de control de entrada. Para una mayor precisión, generalmente se escribe en forma incremental con $\Delta u(k)$ reemplazando a $u(k)$. Esto permite escribir el sistema de ecuaciones de la siguiente manera [9]:

$$\begin{bmatrix} x(k+1) \\ u(k) \end{bmatrix} = \begin{bmatrix} A & B \\ 0 & I \end{bmatrix} \begin{bmatrix} x(k) \\ u(k-1) \end{bmatrix} + \begin{bmatrix} B \\ I \end{bmatrix} \Delta u(k) \quad (4)$$

$$y(k+1) = [C \quad 0] \begin{bmatrix} x(k) \\ u(k-1) \end{bmatrix} \quad (5)$$

Lo cual proporciona un modelo dinámico completo del sistema. Luego, se puede definir una función de costo de la siguiente manera:

$$J(N_p, N_c) = \sum_{j=1}^{N_p} \|y(k+j|k) - w(k+j)\|_R^2 + \sum_{j=1}^{N_c} \|\Delta u(t+j-1)\|_P^2 \quad (6)$$

Donde $\|y(k+j|k) - w(k+j)\|_R^2 = [y(k+j|k) - w(k+j)]^T R [y(k+j|k) - w(k+j)]$, $w(k)$ es la salida de referencia en el tiempo k , N_p es el horizonte de predicción y N_c es el horizonte de control. Observa que el segundo término aplica un peso al cambio en la variable de control, limitando así la rapidez con la que puede cambiar la entrada.

Con la capacidad de calcular la dinámica del sistema, ahora es posible predecir los estados futuros del sistema y, a partir de ahí, encontrar valores óptimos de la variable de control para seguir una salida de referencia. Una representación visual de esta estrategia se muestra en la figura N°6.

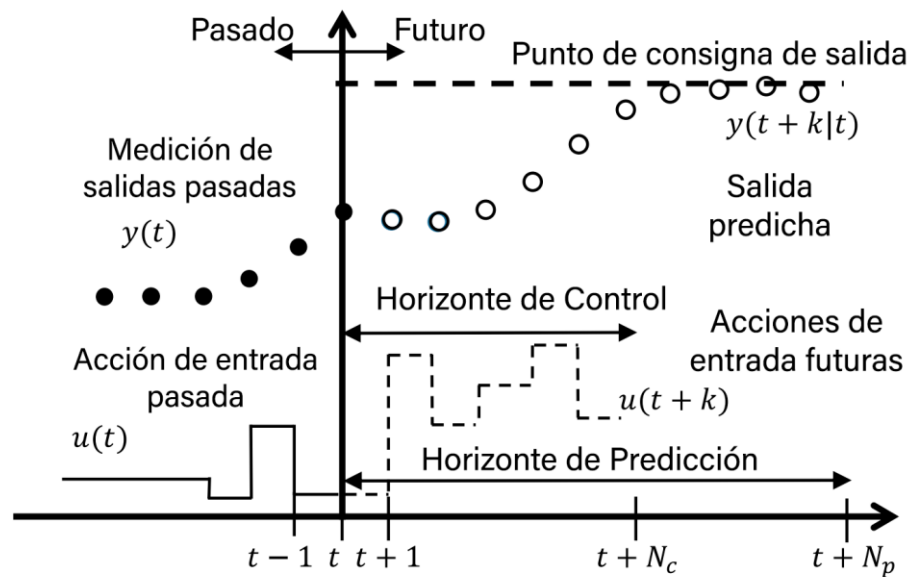


Figura N°6: Esquema de control MPC [9].

La capacidad del MPC para controlar sistemas dentro de ciertos límites, teniendo en cuenta información futura, lo hace ideal para trabajar con microrredes. En particular, un método conocido como control distribuido predictivo basado en modelo (DMPC) es una técnica ideal para controlar un gran número de microrredes con una complejidad mínima. A continuación, se muestra una representación en espacio de estados para una red DMPC:

$$x_i(k+1) = A_{ii}x_i(k) + \sum_{i \neq j} A_{ij}x_j(k) + \sum_{j=1}^N B_{ij}u_j(k) + \sum_{j=1}^N D_{ij}d_j(k) \quad (7)$$

Esta fórmula es similar a la Ec. (2), pero tiene en cuenta el acoplamiento de estados y entradas entre microrredes vecinas en la red. Una idea clave es que cada subsistema de microrred trabaja en conjunto para maximizar una función objetivo global, como se muestra en la ecuación a continuación. Esto se opone a un enfoque descentralizado donde cada subsistema se enfoca únicamente en maximizar una función objetivo local.

$$J_{global} = \sum_{i=1}^N J_{local}^i(x, u) \quad (8)$$

Donde \mathbf{x} y \mathbf{u} son las variables de estado y de entrada respectivamente. Cuando se utiliza un método iterativo para optimizar la red, las variables de interconexión deben definirse como se muestra en la siguiente ecuación.

$$v_i(k) = [u_{1i}(k) \quad u_{2i}(k) \quad u_{3i} \quad \dots \quad u_{Ni}] \quad (9)$$

Donde $u_{ij}(k)$ es la potencia intercambiada entre los subsistemas de microrred \mathbf{i} y \mathbf{j} , calculada por la microrred \mathbf{i} . Para que se alcance una solución, debe cumplirse que $u_{ij}(k) = u_{ji}(k)$.

2.4. Modelado de sistemas y formulación de problemas. El sistema de distribución de energía que se describe y modela es una red de subsistemas de microrredes, cada uno conteniendo una carga controlable, un ESS (sistema de almacenamiento de energía), una RES (fuente de energía renovable) y un generador controlable. La tabla a continuación describe los nombres de variables comúnmente utilizados en este tema.

Tabla I
Nombres y descripciones de variables.

Variable	Descripción
\mathbf{F}_P^L	La potencia prevista de la carga es una matriz de tamaño N por t_f .
\mathbf{F}_P^{RES}	Potencia prevista de fuente de energía renovable. Es una matriz de tamaño N por t_f .

$\mathbf{P}_S(k)$	Potencia de desajuste prevista de las microrredes en el momento k. Es un vector columna de tamaño N.
$\mathbf{P}_P(k)$	Todas las entradas positivas de $\mathbf{P}_S(k)$. Es un vector columna de tamaño N.
$\mathbf{P}_N(k)$	Todas las entradas negativas de $\mathbf{P}_S(k)$. Es un vector columna de tamaño N.
$\mathbf{P}_{Shr}(k)$	La potencia que comparten las microrredes en el momento k es un vector columna de tamaño N. Siempre es igual a $\mathbf{P}_P(k)$, ya que se comparte todo el exceso de potencia.
$\mathbf{P}_{Brw}(k)$	La potencia que toman prestadas las microrredes en el momento k es un vector columna de tamaño N.
$P_i^L(k)$	Potencia de carga prevista de la microrred i en el momento k.
$P_i^{RES}(k)$	Potencia de fuente de energía renovable prevista de la microrred i en el momento k.
$P_i^S(k)$	Potencia de desajuste prevista de la microrred i en el momento k.
\mathbf{F}_α	Necesidad prevista de energía. Es una matriz de tamaño N por t_f . La entrada (i, k) es el porcentaje del exceso de energía del sistema que se destina a la microrred i en el momento k. En otras palabras, la "necesidad de energía" de la microrred i en el momento k.
$\alpha(k)$	Necesidad prevista de potencia en el momento k. Es un vector columna de tamaño N.
$\alpha_i(k)$	Necesidad prevista de energía de la microrred i en el momento k.
N	Número total de microrredes en el sistema.
t_f	Tiempo en horas que dura el pronóstico.

El sistema involucra una red de N microrredes, cada una capaz de operar en modo aislado o conectado a la red. Cada microrred consiste en una carga, un sistema de almacenamiento de energía y una fuente de energía renovable, y puede compartir el estado de cada uno de estos componentes con otras microrredes en el subsistema.

2.4.1. Modelado de carga y RES. A lo largo de esta tesis, se asumirá que los datos pronosticados $F_p^L(k)$ y $F_p^{RES}(k)$ están disponibles con antelación, y se definen como:

$$\mathbf{F}_p^L(k) = [\mathbf{P}_L(1) \quad \mathbf{P}_L(2) \quad \mathbf{P}_L(3) \quad \dots \quad \mathbf{P}_L(t_f)]$$

$$\mathbf{F}_p^{RES}(k) = [\mathbf{P}_{RES}(1) \quad \mathbf{P}_{RES}(2) \quad \mathbf{P}_{RES}(3) \quad \dots \quad \mathbf{P}_{RES}(t_f)]$$

Donde cada entrada $\mathbf{P}_L(k)$ y $\mathbf{P}_{RES}(k)$ se define como la potencia de carga y la potencia de la fuente de energía renovable respectivamente en el tiempo $t = k$, definidos a continuación:

$$\mathbf{P}_L(k) = [P_1^L(k) \quad P_2^L(k) \quad P_3^L(k) \quad \dots \quad P_N^L(k)]^T$$

$$\mathbf{P}_{RES}(k) = [P_1^{RES}(k) \quad P_2^{RES}(k) \quad P_3^{RES}(k) \quad \dots \quad P_N^{RES}(k)]^T$$

A partir de esto, se puede ver que ambas matrices $\mathbf{F}_P^L(k)$ y $\mathbf{F}_P^{RES}(k)$ tienen un tamaño de N por t_f , que son el número de cuadrículas en los sistemas y la longitud local del pronóstico en horas respectivamente.

En este proyecto se puede asumir que el pronóstico predice con precisión la potencia de la fuente de energía renovable (RES) y la carga de los subsistemas. Sin embargo, en [10], se utilizan mediciones en tiempo real del sistema RES para actualizar el pronóstico y ajustar el valor a uno más cercano al valor real.

$$P_i^{RES}(k+1) = P_i^{RES}(k) + \alpha_r \left(P_i^r(k) - P_i^{RES}(k) \right) \quad (10)$$

Donde $P_i^{RES}(k+1)$ es la potencia renovable pronosticada k , $P_i^r(k)$ es la potencia renovable real en el tiempo k , y α_r es una constante de suavizado. Sin embargo, con base en las suposiciones previamente mencionadas, esta ecuación no se utilizará en la representación en espacio de estados de la dinámica del sistema.

Utilizando la potencia de carga y la potencia de la fuente de energía renovable (RES), se define el pronóstico de desajuste de potencia como:

$$\mathbf{P}_S(k) = \mathbf{P}_{RES}(k) - \mathbf{P}_L(k) = \mathbf{P}_P(k) + \mathbf{P}_N(k) \quad (11)$$

Donde el desajuste de potencia, \mathbf{P}_S , se ha dividido en partes positivas y negativas, \mathbf{P}_P y \mathbf{P}_N , respectivamente.

2.5. Sistema de almacenamiento de energía. El sistema de almacenamiento de energía es clave para que la microrred pueda manejar de manera fluida la naturaleza intermitente de las fuentes de energía renovable, almacenando el exceso de energía en momentos de sobreproducción y utilizándola durante los períodos de subproducción. La dinámica de este modelo se muestra en la ecuación a continuación:

$$E_i(k+1) = E_i(k) + \eta_i P_i^b(k) \quad (12)$$

$$E_{min} \leq E_i(k) \leq E_{max} \quad (13)$$

Donde $E_i(k)$ es la energía del sistema de almacenamiento, η_i es la eficiencia de carga y $P_i^b(k)$ es la potencia que entra en el sistema de almacenamiento de energía, todos relevantes para el subsistema de microrred i -ésima en la red.

2.5.1. Balance de potencia. Supongamos que cada microrred está trabajando cooperativamente en modo aislado, lo que significa que cada una debe satisfacer una carga local, pero pueden compartir el exceso de potencia con las microrredes vecinas. Esto implica que la potencia de carga puede provenir de ESS, RES, generadores

controlables locales o de microrredes vecinas. Por lo tanto, se pueden definir las siguientes ecuaciones de balance de potencia:

$$P_i^b(k) = P_i^S(k) + P_{ij}(k) + P_i^C(k) \quad (14)$$

$$P_{ij}(k) = \alpha_i \sum_{j \neq i} P_j(k) \quad (15)$$

$$P_{ij}(k) \geq 0 \quad (16)$$

Donde $P_i^S(k)$ ha sido definido en la Ec. (11), $P_i^C(k)$ es la potencia producida por el generador controlable, $P_{ij}(k)$ es la potencia que llega a la microrred i desde la microrred j , y α_i es el porcentaje del exceso total de potencia que se entrega a la microrred i .

2.5.2. Modelado del sistema. Un modelo en espacio de estados que represente la dinámica del sistema se puede crear utilizando las Ec. (14) y (12) definiendo las variables de estado $x_i(k)$ como:

$$x_i(k) = \begin{bmatrix} E_i(k+1) \\ n_j(k) \\ P_i^{RES}(k) \end{bmatrix} \quad (17)$$

Lo cual permite definir la siguiente representación en espacio de estados:

$$x_i(k+1) = Mx_i(k) + Qu_i(k) + A_i \sum_{j=1, j \neq i}^N x_j(k) + B_i \sum_{j=1, j \neq i}^N u_j(k) \quad (18)$$

Donde:

$$M = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (19)$$

$$Q = \begin{bmatrix} -1 \\ 0 \end{bmatrix} \quad (20)$$

$$A_i = \begin{bmatrix} 0 & \alpha_i & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (21)$$

$$B_i = \begin{bmatrix} -\alpha_i \\ 0 \end{bmatrix} \quad (22)$$

Sujeto a las Ec. (16) y (23).

2.6. Propuesta de control predictivo distribuido. Se eligió un esquema de control distribuido cooperativo para superar los desafíos de la naturaleza incierta de las fuentes de energía renovable (RES), controlando el uso del exceso de energía en otras microrredes del subsistema. Para lograr esto, cada subsistema debe tener información sobre los otros subsistemas en la red, lo cual se logra implementando un MA local que tiene acceso a un modelo de predicción ampliado que tiene en cuenta todos los subsistemas en la red. Este modelo ampliado se puede escribir como:

$$\bar{x}(k+1|k) = A\bar{x}(k|k) + B\bar{u}(k|k) \quad (23)$$

Donde:

$$\begin{aligned} \bar{x}(k) &= [x_1(k|k) \quad x_2(k|k) \quad \dots \quad x_N(k|k)]^T \\ u(k) &= [x_1(k|k) \quad x_2(k|k) \quad \dots \quad x_N(k|k)]^T \end{aligned}$$

Basándose en la Ec. (18), las matrices A y B se pueden definir de la siguiente manera,

$$A = \begin{bmatrix} M & A_1 & A_1 & \dots & A_1 \\ A_2 & M & A_2 & \dots & A_2 \\ A_3 & A_3 & M & \dots & A_3 \\ \dots & \dots & \dots & \dots & \dots \\ A_N & A_N & A_N & \dots & M \end{bmatrix} \quad (24)$$

$$B = \begin{bmatrix} Q & B_1 & B_1 & \dots & B_1 \\ B_2 & Q & B_2 & \dots & B_2 \\ B_3 & B_3 & Q & \dots & B_3 \\ \dots & \dots & \dots & \dots & \dots \\ B_N & B_N & B_N & \dots & Q \end{bmatrix} \quad (25)$$

Donde M, A_i, B_i y Q se definen en las Ec. (19), (21), (22) y (20) respectivamente. Sin embargo, para utilizar estas fórmulas, es necesario determinar métodos para encontrar los valores de las variables clave, lo cual se explorará en el resto de esta sección.

2.7. Coeficiente de compartición de potencia de la microrred. El coeficiente de compartición de potencia para la i -ésima microrred, $\alpha_i(k)$, es el porcentaje total del exceso de potencia que se entrega a la microrred i . Estos valores se almacenan en la matriz F_α donde la entrada (i,k) -ésima es el coeficiente de compartición de potencia de la microrred MG i en el tiempo k , que representa la "Necesidad de Potencia" de la microrred i en el tiempo k . Esta matriz se representa de la siguiente manera:

$$F_\alpha = [\alpha(1) \quad \alpha(2) \quad \dots \quad \alpha(t_f)] \quad (26)$$

Donde:

$$\alpha(1) = \begin{bmatrix} \alpha_1(1) \\ \alpha_2(1) \\ \dots \\ \alpha_N(1) \end{bmatrix} \quad (27)$$

Para encontrar el coeficiente de compartición de potencia α_i , se debe definir la siguiente función de costo.

$$G(\alpha(k)) = \sum_{i=1}^N \left[P_i^N(k) + \alpha_i(k) \sum_{n=1}^N P_n^P(k) \right]^2 \quad (28)$$

Sujeto a las siguientes restricciones:

$$\sum_{i=1, P_i^S(k) < 0}^N \alpha_i = 1 \quad (29)$$

$$\alpha_{i, P_i^S(k) > 0} = 0 \quad (30)$$

Donde $\alpha_{i, P_i^S(k) < 0}$ son los valores de α en las microrredes $P_i^S(k) < 0$ es la potencia de déficit, y $P_i^N(k)$ es el exceso de potencia con respecto a la i -ésima microrred.

2.8. Potencia prestada y compartida. Entonces, la matriz $\mathbf{P}_{ij}(k)$, que presenta la potencia enviada desde la microrred j hacia la micro-red i en el tiempo k , se puede crear a partir de la siguiente ecuación:

$$\mathbf{P}_{ij}(k) = \alpha(k) P_p(k)^T = \begin{bmatrix} \alpha_1(k) \\ \alpha_2(k) \\ \dots \\ \alpha_N(k) \end{bmatrix} [P_{P,1}(k) \quad P_{P,2}(k) \quad \dots \quad P_{P,N}(k)] \quad (31)$$

Donde cada columna $\mathbf{P}_{ij}(k)$ representa la potencia compartida por la microrred j hacia todas las otras microrredes $i \neq j$.

Las potencias prestadas y compartidas son variables únicas en esta tesis y son útiles para calcular rápidamente la potencia de la batería sin recurrir a cadenas de declaraciones if/elseif. Recuerde que cada columna de $\mathbf{P}_{ij}(k)$ representa la potencia compartida por la microrred j hacia todas las otras microrredes $i \neq j$. Por lo tanto, la suma de todas estas columnas resultará en un vector columna único de tamaño N , donde cada entrada representa la potencia total prestada por la microrred i en el tiempo k . Esto es exactamente la variable deseada, $\mathbf{P}_{Brw}(k)$, y se puede escribir de la siguiente manera:

$$\mathbf{P}_{Brw}(k) = \mathbf{P}_{ij}(k) \mathbf{1}_{N,1} \quad (32)$$

Del mismo modo, sumando las filas de $\mathbf{P}_{ij}(k)$, se puede determinar la potencia compartida, que se puede calcular mediante la siguiente ecuación:

$$\mathbf{P}_{Shr}(k) = \mathbf{P}_{ij}(k)^T \mathbf{1}_{N,1} \quad (33)$$

Donde $\mathbf{1}_{N,1}$ y $\mathbf{1}_{1,N}$ son vectores columna y fila, respectivamente, de tamaño N llenos de unos.

2.8.1. Energía en ESS. Utilizando los resultados de la sección anterior, puedo definir la potencia que ingresa al ESS como:

$$\mathbf{P}_b(k) = \mathbf{P}_S(k) + \mathbf{P}_{Brw}(k) - \mathbf{P}_{Shr}(k) = [P_{b,1}(k) \quad P_{b,2}(k) \quad \dots \quad P_{b,N}(k)]^T \quad (34)$$

Equivalente a:

$$P_i^b(k) = P_i^S(k) + P_i^{Brw}(k) - P_i^{Shr}(k) \quad (35)$$

A partir de ahí, la eficiencia de carga de la microrred i se puede definir como:

$$\eta_i(k) = \begin{cases} \eta_{ch}, & P_{b,i}(k) > 0 \\ \frac{1}{\eta_{ach}}, & P_{b,i}(k) < 0 \end{cases}$$

Entonces puedo definir la siguiente matriz diagonal:

$$\eta(k) = \begin{bmatrix} \eta_1(k) & 0 & \dots & 0 \\ 0 & \eta_2(k) & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \eta_N(k) \end{bmatrix} \quad (36)$$

A continuación, el nivel de energía en la batería puede definirse como:

$$\mathbf{E}(k+1) = \mathbf{E}(k) + \boldsymbol{\eta} \mathbf{P}_b(k) \quad (37)$$

Se podrían utilizar varias herramientas de solución de MPC para controlar el sistema utilizando las siguientes variables de estado: $\mathbf{x}(k) = \mathbf{E}(k)$, $\mathbf{u}(k) = \mathbf{P}_b(k)$, $\mathbf{A} = \mathbf{I}$ y $\mathbf{B}(k) = \boldsymbol{\eta}(k)$. Sin embargo, en esta forma la variable de control es la potencia de la batería en lugar de la potencia de carga.

La energía dentro de cada sistema de almacenamiento de energía (ESS) luego se determina mediante la siguiente función de costo, utilizando la ecuación (37), y se utiliza para proteger el ESS de los daños que pueden ocurrir debido a la descarga profunda.

$$J_{i,1}(E_i(k)) = (\min(E_i(k) - E_{min}, 0))^2 \quad (38)$$

Bajo la restricción

$$E_{min} \leq E_i(k) \leq E_{max} \quad (39)$$

2.9. Optimización de la potencia de carga. Antes de que se pueda calcular la potencia óptima de carga, es útil reescribir varias fórmulas en términos de potencia de carga, de modo que se pueda escribir una función de costo en términos de una única variable de entrada, que en este caso es la potencia de carga.

2.9.1. Energía en el sistema de almacenamiento de energía (ESS). El primer paso para reescribir la Ec. (37) es expandirla a la siguiente forma:

$$\mathbf{E}(k+1) = \mathbf{E}(k) + \boldsymbol{\eta}(k)[\mathbf{P}_{RES}(k) - \mathbf{P}_L(k) + \mathbf{P}_{Brw}(k) - \mathbf{P}_{Shr}(k)] \quad (40)$$

Alternativamente, se puede encontrar una expresión explícita para la energía en el ESS de la i -ésima microrred como:

$$E_i(k+1) = E_i(k) + \eta_i(k)P_i^b(k) \quad (41)$$

Uno de los objetivos es simplificar el algoritmo, lo cual requiere que todas las ecuaciones se escriban en términos de las variables de entrada, que en este caso es la potencia de carga $P_i^L(k)$. Para lograr esto, es necesario establecer una expresión para la potencia de la batería $P_i^b(k)$ en términos de la potencia de carga.

2.9.2. Potencia prestada y compartida. Puedo definir una función $\gamma_i(k)$ que sea 1 cuando $P_i^S(k) \geq 0$ y 0 cuando $P_i^S(k) < 0$, lo cual se puede escribir como:

$$\gamma_i(k) = \begin{cases} 1, & P_i^{RES}(k) \geq P_i^L(k) \\ 0, & P_i^{RES}(k) < P_i^L(k) \end{cases} \quad (42)$$

Puedo entonces definir la matriz diagonal $\Gamma(k)$ como:

$$\Gamma(k) = \begin{bmatrix} \gamma_1(k) & 0 & \dots & 0 \\ 0 & \gamma_2(k) & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \gamma_N(k) \end{bmatrix} \quad (43)$$

Puedo entonces definir $\mathbf{P}_P(k)$ como:

$$\mathbf{P}_P(k) = \Gamma(k)\mathbf{P}_S(k) = \Gamma(k)[\mathbf{P}_{RES}(k) - \mathbf{P}_L(k)] \quad (44)$$

Entonces, $\mathbf{P}_N(k)$ puede definirse fácilmente como:

$$\mathbf{P}_N(k) = \mathbf{P}_S(k) - \mathbf{P}_P(k) = [\mathbf{I}_N - \Gamma(k)][\mathbf{P}_{RES}(k) - \mathbf{P}_L(k)] \quad (45)$$

Por lo tanto, puedo reescribir la Ec. (31) sustituyendo la Ec. (44) para obtener la siguiente expresión:

$$\mathbf{P}_{ij}(k) = \alpha(k)[\mathbf{P}_{RES}(k) - \mathbf{P}_L(k)]^T \Gamma(k)^T \quad (46)$$

Dado que se supone un conocimiento perfecto de RES para fines de optimización, y se supone que $\alpha(k)$ se optimizó en un paso anterior, $\mathbf{P}_{ij}(k)$ puede escribirse como una función puramente de la variable de control, que es la potencia de carga.

Esto significa que combinando las Ec. (32), (33) y (46), la potencia prestada y compartida se puede expresar como una función de la potencia de carga, como se muestra a continuación:

$$\mathbf{P}_{Brw}(\mathbf{P}_L(k)) = \alpha(k)[\mathbf{P}_{RES}(k) - \mathbf{P}_L(k)]^T \quad (47)$$

$$\mathbf{P}_{Shr}(k) = \Gamma(k)[\mathbf{P}_{RES}(k) - \mathbf{P}_L(k)]\alpha(k)^T \mathbf{1}_{N,1} \quad (48)$$

2.9.3. Potencia de batería. Sustituyendo la Ec. (46) en la Ec. (34), se puede determinar una nueva expresión para $\mathbf{P}_b(k)$.

$$\mathbf{P}_b(k) = \mathbf{P}_{RES}(k) - \mathbf{P}_L(k) + \mathbf{P}_{Brw}(\mathbf{P}_L(k)) - \mathbf{P}_{Shr}(\mathbf{P}_L(k)) \quad (49)$$

Al sustituir las Ec. (47) y (48), se obtiene una expresión para la potencia que entra en el ESS de los microgrids en el tiempo k , en términos únicamente de la variable de entrada, $\mathbf{P}_L(k)$, y una constante conocida, $\mathbf{P}_{RES}(k)$:

$$\begin{aligned} \mathbf{P}_b(k) = & \mathbf{P}_{RES}(k) + \boldsymbol{\alpha}(k)\mathbf{P}_{RES}(k)^T\boldsymbol{\Gamma}(k)^T\mathbf{1}_{N,1} - \boldsymbol{\Gamma}(k)\mathbf{P}_{RES}(k)\boldsymbol{\alpha}^T\mathbf{1}_{N,1} \\ & + \boldsymbol{\Gamma}(k)\mathbf{P}_L(k)\boldsymbol{\alpha}^T\mathbf{1}_{N,1} - \mathbf{P}_L(k) - \boldsymbol{\alpha}(k)\mathbf{P}_L(k)^T\boldsymbol{\Gamma}(k)^T\mathbf{1}_{N,1} \end{aligned} \quad (50)$$

Donde $\mathbf{P}_b(k)$ es un vector columna de tamaño N , donde el i -ésimo elemento $P_i^b(k)$ representa la potencia entrante al i -ésimo subsistema ESS.

Para simplificar la ecuación y separar las constantes de las variables, se puede definir la siguiente variable:

$$\mathbf{H}(k) = \mathbf{P}_{RES}(k) + \boldsymbol{\alpha}(k)\mathbf{P}_{RES}(k)^T\boldsymbol{\Gamma}(k)\mathbf{1}_{N,1} - \boldsymbol{\Gamma}(k)\mathbf{P}_{RES}(k)\boldsymbol{\alpha}^T\mathbf{1}_{N,1} \quad (51)$$

2.9.4. Modelo dinámico. Utilizando las ecuaciones (40) y (50), la ecuación para la energía en el sistema de almacenamiento de energía de la i -ésima microred puede escribirse como:

$$\begin{aligned} \mathbf{E}(k+1) = & \mathbf{E}(k) \\ & + \boldsymbol{\eta}[\mathbf{H}(k) + \boldsymbol{\Gamma}(k)\mathbf{P}_L(k)\boldsymbol{\alpha}^T\mathbf{1}_{N,1} - \mathbf{P}_L(k) - \boldsymbol{\alpha}(k)\mathbf{P}_L(k)^T\boldsymbol{\Gamma}(k)^T\mathbf{1}_{N,1}] \end{aligned} \quad (52)$$

Debido a la complejidad de estas ecuaciones, no es posible formar una representación típica en espacio de estados a partir de esta ecuación. Sin embargo, cumple la misma función, ya que permite calcular $E(k+n|k)$.

Se pueden definir dos funciones de costo adicionales para ayudar en el control de la potencia de la carga. El nivel de satisfacción del cliente $J_2(\mathbf{P}_L(k))$ y el nivel de utilización de energía renovable $J_3(\mathbf{P}_L(k))$, definidos a continuación:

$$J_2(\mathbf{P}_L(k)) = \text{sum} \left\{ \min[\mathbf{P}_L(k) - \mathbf{P}_{L,fc}(k), 0]^2 \right\} \quad (53)$$

$$J_3(\mathbf{P}_L(k)) = \text{sum} \{ \min[\mathbf{P}_{RES}(k) - \mathbf{P}_L(k), 0]^2 \} \quad (54)$$

Donde $\mathbf{P}_{L,fc}(k)$ es la potencia de carga prevista en el momento k .

La primera función de costo puede reescribirse en términos de la potencia de la carga de la siguiente manera, utilizando la Ec. (52):

$$J_1(\mathbf{P}_L(k)) = \text{sum} \left\{ [\min(\mathbf{E}(\mathbf{P}_L(k)) - \mathbf{E}_{min}, 0)]^2 \right\} \quad (55)$$

Las siguientes restricciones pueden añadirse para asegurar que la potencia de la carga optimizada se mantenga dentro de los límites operativos.

$$\mathbf{P}_{L,min} \leq \mathbf{P}_i^L(k) \leq \mathbf{P}_{L,max} \quad (56)$$

Se puede crear una función de costo total combinando las funciones de costo en las Ec. (53), (54) y (55), y sumándolas para cada microred (MG) en el sistema.

$$J(P_L) = \sum_{m=1}^{N_p} [\chi_1 J_1(P_L(k+m|k)) + \chi_2 J_2(P_L(k+m|k)) + \chi_3 J_3(P_L(k+m|k))] \quad (57)$$

Donde χ_i es la ponderación de la i -ésima función de costo del MGs J_i . Se puede crear una función de costo total combinando las funciones de costo en las Ec. (53), (54) y (55), y sumándolas para cada microred (MG) en el sistema.

$$J(P_L) = \sum_{m=1}^{N_p} [\chi_1 J_1(P_L(k+m|k)) + \chi_2 J_2(P_L(k+m|k)) + \chi_3 J_3(P_L(k+m|k))] \quad (58)$$

Donde χ_i es la ponderación de la i -ésima función de costo del MGs J_i .

2.9.5. Potencia de carga óptima. En las secciones anteriores se han presentado la función de costo y la dinámica del sistema, que son los dos componentes clave necesarios para optimizar un sistema utilizando control predictivo basado en modelos. Por lo tanto, al implementar la Ec. (52) para predecir la energía, se puede construir la función de costo en la Ec. (57), que luego puede ser minimizada para encontrar un valor óptimo de la potencia de carga en el tiempo k utilizando cualquier herramienta de optimización.

2.10. Potencia de generador controlada. Los valores de $P_i^C(k)$ podrían entonces ser seleccionados para satisfacer la ecuación:

$$P_i^L(k) = P_i^{RES}(k) + P_i^C(k)$$

Lo cual permite el control y la optimización del flujo de energía en las microrredes (MGs) basado en los valores pronosticados.

2.10.1. Algoritmo propuesto. Con los resultados obtenidos en las secciones anteriores, puedo proponer 3 algoritmos que, en conjunto, forman el sistema completo de gestión de energía. El primer algoritmo encuentra los valores óptimos del coeficiente de reparto de potencia α y se muestra a continuación.

Algoritmo 1: Optimización del coeficiente de reparto de potencia.

- 1: Inicializar $\mathbf{P}_L(k), \mathbf{P}_{RES}(k), \forall k 1, 2, 3, \dots, N$
- 2: Calcular $\mathbf{P}_S(k) = \mathbf{P}_{RES}(k) - \mathbf{P}_L(k)$
- 3: Calcular $\mathbf{\Gamma}(k)$ usando las Ec. (43) y (44)

- 4: for $i = 1$ a $i = N$
- 5: If $P_i^S(k) < 0$
- 6: $G_i(k) = [P_i^S(k) + \alpha_i(k) \sum_{n=1}^N P_n^P(k)]^2$
- 7: else
- 8: Set $G_i(k) = 0$
- 9: end for
- 10: Calcular la función de costo (28) utilizando la fórmula $G(\alpha(k)) = \sum_{i=1}^N G_i(k)$
- 11: Calcular el valor de $\alpha(k)$ minimizando la función de costo $G(\alpha(k))$ sujeta a las restricciones de las Ec. (29) y (30).

El siguiente algoritmo propuesto, que se muestra a continuación, es el algoritmo de programación de la potencia, el cual calcula la potencia que entra en los sistemas de almacenamiento de energía (ESS) y determina si cada subsistema está cargando o descargando.

Algoritmo 2: Programación de coordinación de potencia.

- 1: Inicializar $\mathbf{P}_L(k), \mathbf{P}_{RES}(k), \forall k 1, 2, 3, \dots, N$
- 2: Calcular $\mathbf{\Gamma}(k)$ usando Ec. (43) y (44)
- 3: Calcular $\mathbf{P}_b(k)$ usando Ec. (50)
- 4: Si $P_i^b(k) > 0$, el i -ésimo MGs ESS se está cargando, de lo contrario se está descargando, donde $P_i^b(k)$ es la i -ésima entrada de $\mathbf{P}_b(k)$

El algoritmo final propuesto es el MPC distribuido, que se muestra a continuación, en el que se calculan valores óptimos de la potencia de carga utilizando técnicas iterativas.

Los algoritmos se utilizan de forma secuencial para optimizar todo el sistema. Primero se encuentra el coeficiente de distribución de potencia α , que luego se utiliza para encontrar la potencia que ingresa al i -ésimo MG ESS $\mathbf{P}_b(k)$, que luego se utiliza para calcular la potencia de carga óptima $\mathbf{P}_{L,opt}(k)$.

Algoritmo 3: Propuesta de MPC distribuido

- 1: Inicialización $\mathbf{P}_L(k), \mathbf{P}_{RES}(k), \forall k 1, 2, 3, \dots, N$
- 2: for $k = 1$ a $k = tf$ **do**
- 3: until convergence
- 4: Calcular $P_{L,opt}(k)$ óptimo, minimizando la función de costo (57)
- 5: Enviar $P_{Shr}(k)$ a MG vecinos y recibir $P_{Brw}(k)$ de ellos.
- 6: Implementar carga optimizada $P_L(k) = P_{L,opt}(k)$
- 7: Incrementar $k = k + 1$
- 8: end for

III. RESULTADOS

3.1. Presentación e interpretación de los resultados.




Figura N°7: Potencia de carga optimizada.

Interpretación:

En la figura N°7 se obtiene La metodología propuesta se ha aplicado a una red simulada de 3 microrredes; se presenta la potencia de carga optimizada.

La energía inicial en los sistemas de almacenamiento de energía (ESS) se definió como $E_i(0) = 40\text{pu}$, con una energía mínima y máxima definida como $E_{min} = 5\text{pu}$, y $E_{max} = 60\text{pu}$ respectivamente. La eficiencia de carga se definió como $\eta_{ch} = 0.7$, $\eta_{dch} = 0.65$, y los horizontes de control y predicción utilizados fueron $N_c = 1$, $N_p = 4$.

A partir de la siguiente figura, se puede observar que se aplicaron métodos de control de carga cuando la energía proveniente de las fuentes de energía renovable (RES) no fue suficiente para cubrir la carga.




Figura N°8: Proporción Optimizada de Utilización de Energía Renovable.

Interpretación:

En la figura N°8 se presenta la proporción optimizada de utilización de energía renovable. Como resultado, un porcentaje mayor de la potencia total consumida fue suministrado por fuentes de energía renovable (RES), lo que resultó en un valor más alto del REUR, definido en la Ec. (1), como se puede observar en la figura N°8.




Figura N°9: Energía Optimizada y No Optimizada en ESS.

Interpretación:

En la figura N°9 se presenta la energía optimizada y no optimizada en ESS. Este aumento en la utilización de las fuentes de energía renovable disponibles es especialmente evidente durante el tiempo $5 \leq t \leq 17$. Esto demuestra que la metodología propuesta tiene éxito en su objetivo de maximizar la utilización de las fuentes de energía renovable (RES).

Es importante señalar que, si las potencias de carga en todas las microrredes son mayores que las potencias renovables disponibles, el REUR optimizado será el mismo. De lo contrario, el REUR optimizado será mayor que el original, lo que garantiza que los algoritmos producirán una utilización igual o mejor de las RES.

Las restricciones que permite el control predictivo basado en modelos también aseguran que los sistemas de almacenamiento de energía (ESSs) se mantengan dentro de límites aceptables, como se muestra en la figura siguiente, lo que conduce a una mayor vida útil de los dispositivos y mejor rendimiento del sistema.

Basándose en las figuras 8, 9 y 10, se puede determinar que el objetivo propuesto de maximizar el REUR teniendo en cuenta las restricciones del sistema es un éxito.

3.2. Contrastación de hipótesis.

3.2.1. Hipótesis específicas.

Muestra: Identificar la unidad de análisis que también es la unidad muestral, en este caso, es la optimización de la tasa de utilización de energías renovables, existentes en la empresa Nexa Resources Peru.

Hipótesis específica 1

H_1 : Con el modelado de una red de subsistemas de microrred se mejora la utilización de la fuente de energía renovables.

H_0 : Con el modelado de una red de subsistemas de microrred no se mejora la utilización de la fuente de energía renovables.

Decisión.

El valor obtenido es menor a la región crítica $\alpha = 0,05$ (nivel de significancia 5%); entonces rechazamos la hipótesis nula y aceptamos la hipótesis alterna.

Se concluye que con el modelado de una red de subsistemas de microrred se mejora la utilización de la fuente de energía renovables.

Hipótesis específica 2.

H_1 : Con el control predictivo basado en modelos se establece el coeficiente de reparto de energía en el sistema de almacenamiento de energía.

H_0 : Con el control predictivo basado en modelos no se establece el coeficiente de reparto de energía en el sistema de almacenamiento de energía.

Decisión.

El valor obtenido es menor a la región crítica $\alpha = 0,05$ (nivel de significancia 5%); entonces rechazamos la hipótesis nula y aceptamos la hipótesis alterna.

Se concluye que con el control predictivo basado en modelos se establece el coeficiente de reparto de energía en el sistema de almacenamiento de energía.

3.2.2. Hipótesis general.

H_1 : Con el control predictivo basado en modelos se optimiza la tasa de utilización de energías renovables.

H_0 : Con el control predictivo basado en modelos no se optimiza la tasa de utilización de energías renovables.

Decisión.

El valor obtenido es menor a la región crítica $\alpha = 0,05$ (nivel de significancia 5%); entonces rechazamos la hipótesis nula y aceptamos la hipótesis alterna.

Se concluye que con el control predictivo basado en modelos se optimiza la tasa de utilización de energías renovables.

IV. DISCUSIÓN

Birunda y Narmadha (2023) emplearon el control predictivo del modelo (MPC) para gestionar la energía en sistemas híbridos, enfocándose en la estabilidad y fiabilidad de la energía. Su estudio, basado en simulaciones con MATLAB/Simulink, reveló mejoras significativas en la división óptima de potencia y la estabilidad del sistema. Comparando estos antecedentes con los resultados actuales, se observa que ambos enfoques coinciden en utilizar técnicas de MPC para optimizar la utilización de energía renovable. Sin embargo, los resultados actuales muestran un enfoque más avanzado al aplicar el MPC a una red simulada de 3 microrredes, logrando maximizar la utilización de fuentes de energía renovable (RES) con éxito. Mientras que Birunda y Narmadha centraron su investigación en la predicción de errores, el enfoque actual incluye la optimización en tiempo real de múltiples microrredes, lo que representa un avance en la gestión energética.

Gao et al. (2023) propusieron un modelo de predicción híbrido integrado en un marco de MPC, mejorando significativamente la seguridad de la batería y la operación continua de energía y calor. En comparación con estos resultados, los actuales también aplican MPC, pero en una red simulada de 3 microrredes, optimizando la utilización de energía renovable y manteniendo la eficiencia del almacenamiento de energía (ESS). Aunque ambos estudios se centran en mejorar la eficiencia energética, Gao et al. se enfocaron en la seguridad y continuidad operativa, mientras que los resultados actuales se orientan hacia la maximización del uso de fuentes renovables y la prolongación de la vida útil de los dispositivos ESS. Esta comparación resalta cómo el enfoque actual ha ampliado el uso de MPC a un contexto más complejo y diversificado, integrando múltiples microrredes y fuentes de energía.

Andia (2021) implementó un control predictivo basado en modelos (CPBM) asociado a un control neurodifuso para optimizar la gestión energética en microrredes con fuentes renovables. Su enfoque, que incluía el uso de estructuras paramétricas y algoritmos de solución distribuida, demostró ser eficaz en la optimización del uso de energía y la sostenibilidad del sistema. Comparando estos antecedentes con los resultados actuales, se nota que ambos trabajos utilizan CPBM para maximizar la eficiencia energética. Sin embargo, los resultados actuales se centran más en la optimización del uso de energías renovables en una red simulada de 3 microrredes, lo que incluye un análisis detallado de la proporción optimizada de utilización de energía renovable y el rendimiento de los sistemas de almacenamiento de energía (ESS). Este enfoque refleja un avance hacia la aplicación práctica de estrategias de control predictivo en sistemas más complejos y dinámicos.

V. CONCLUSIONES

Mis resultados demuestran una optimización significativa en la utilización de fuentes de energía renovable (RES) en una red simulada de 3 microrredes. La metodología propuesta logra que un porcentaje mayor de la potencia total consumida provenga de RES, lo que se traduce en un valor más alto de la proporción optimizada de utilización de energía renovable. Esto indica que el enfoque aplicado es exitoso en su objetivo de maximizar el uso de energías limpias, minimizando la dependencia de fuentes no renovables y reduciendo el impacto ambiental. La metodología no solo asegura el suministro adecuado de energía, sino que también contribuye a la sostenibilidad del sistema, lo que es esencial en el contexto de transición energética hacia modelos más verdes y eficientes.

Mi investigación muestra una mejora notable en la gestión de los sistemas de almacenamiento de energía (ESS). La metodología aplicada garantiza que los ESS se mantengan dentro de límites aceptables, lo que no solo optimiza su rendimiento, sino que también extiende su vida útil. Este control eficiente de la energía almacenada es crucial para asegurar la continuidad del suministro energético, especialmente durante períodos en los que la generación de energía renovable no es suficiente para cubrir la demanda. Además, la optimización de la energía en los ESS durante ciertos intervalos de tiempo refleja una mayor eficiencia en la gestión energética, permitiendo un uso más inteligente y prolongado de los recursos disponibles.

La implementación de estrategias de control predictivo ha sido efectiva en lograr los objetivos planteados en la gestión de las microrredes simuladas. El enfoque aplicado permite maximizar la utilización de las RES, asegurando al mismo tiempo que los ESS operen de manera óptima y dentro de sus límites operacionales. Esta estrategia de control no solo ha demostrado ser robusta y eficiente, sino que también es adaptable a las variaciones en la demanda y disponibilidad de energía, lo que la hace idónea para aplicaciones en entornos energéticos complejos y dinámicos. La capacidad de predecir y ajustar las variables de control en tiempo real es fundamental para mantener un equilibrio energético y asegurar un suministro constante y sostenible.

VI. RECOMENDACIONES

Para mejorar la optimización de la utilización de energía renovable, se recomienda integrar algoritmos de inteligencia artificial, como el aprendizaje por refuerzo y redes neuronales, en las estrategias de control predictivo. Estos algoritmos pueden adaptarse a condiciones variables y mejorar la precisión en la predicción y la toma de decisiones en tiempo real. La IA puede analizar grandes volúmenes de datos de diferentes fuentes de energía y ajustar dinámicamente las operaciones del sistema para maximizar el uso de energías renovables. Esto no solo incrementaría la eficiencia del sistema, sino que también podría reducir la necesidad de intervención manual, permitiendo una operación más autónoma y resiliente frente a fluctuaciones en la generación y demanda de energía.

Es recomendable desarrollar modelos de simulación que incluyan escenarios más complejos y realistas, integrando factores como la variabilidad climática, el crecimiento de la demanda energética y la integración de nuevas tecnologías de almacenamiento. Al simular condiciones más diversas, se pueden identificar desafíos potenciales y oportunidades de mejora en la gestión de la energía. Además, estos modelos pueden ayudar a evaluar la escalabilidad y robustez de las estrategias de control predictivo en situaciones más extremas, lo que es esencial para asegurar la sostenibilidad y resiliencia del sistema en el futuro. Estos modelos también pueden ser útiles para probar nuevas tecnologías o estrategias antes de implementarlas en entornos reales.

Para avanzar en la gestión de los sistemas de almacenamiento de energía (ESS) y la maximización de fuentes renovables, se recomienda explorar la optimización multicriterio en futuras investigaciones. Este enfoque permitiría considerar múltiples objetivos simultáneamente, como minimizar los costos operativos, maximizar la vida útil del ESS, y reducir la huella de carbono, entre otros. Al abordar varios criterios de optimización, los investigadores pueden desarrollar estrategias más equilibradas y eficientes que no solo mejoren el rendimiento energético, sino que también optimicen el costo y la sostenibilidad ambiental. Este tipo de investigación es clave para diseñar sistemas de gestión de energía más robustos y adaptativos, capaces de manejar las complejidades de las microrredes modernas.

VII. REFERENCIAS BIBLIOGRÁFICAS

- [1] V. Birunda y T. Narmadha, “Optimization of Integrated Hybrid Systems Using Model Predictive Controller”, *Electric, Power Components and Systems*, vol. 52, nro. 1, pp. 82 – 98, 2023.
- [2] M. Lin et al., “Reinforcement Learning-Based Model Predictive Control for Discrete-Time Systems”, *IEEE Transactions on Neural Networks and Learning Systems*, vol. 35, nro. 3, pp. 3312 – 3324, 2024.
- [3] K. Kumar y S. Bae, “Coordinated Dynamic Power Management for Renewable Energy-Based Grid-Connected Microgrids Using Model Predictive Control”, *IEEE Transactions on Industrial Informatics*, vol. 99, pp. 1 – 13, 2023.
- [4] Y. Gao et al., “Model predictive control of a building renewable energy system based on a long short-term hybrid model”, *Sustainable Cities and Society*, vol. 89, nro. 104317, 2023.
- [5] B. Thaler et al., “Hybrid model predictive control of renewable microgrids and seasonal hydrogen storage”, *International Journal of Hydrogen Energy*, vol. 48, nro. 97, pp. 38125 – 3814, 2023.
- [6] N. Benites, “Control predictivo basado en modelo (MBPC) aplicado a un sistema de bombeo solar fotovoltaico”, tesis de pregrado, Facultad de Ingeniería Eléctrica y Electrónica, Universidad Nacional del Callao, Perú, 2019.
- [7] F. Andia, “Control Predictivo Basado en Modelo y Neurodifuso, aplicado a la optimización de energía en microrredes eléctricas con fuentes renovables”, tesis doctoral: Escuela de Postgrado, Universidad Nacional San Luis Gonzaga, Ica, Perú, 2021.
- [8] Y. Du et al., “Distributed MPC for Coordinated Energy Efficiency Utilization in Microgrid Systems”, *IEEE Transactions on Smart Grid*, vol. 10.
- [9] Office of Electricity Delivery and Energy Reliability Smart Grid R&D Program DOE Microgrid Workshop, 2011 Report.
- [10] C. Bordons, “Model predictive control of Microgrids Springer International Publishing”, 2020.