JERARQUÍAS DE CONTROL EN MICRORREDES

Modelado Matemático y Algoritmos de Control

Juan Gabriel Ordóñez
Harold Ruiz Bravo
Laura Rodríguez Rivera
Javier Revelo Fuelagán
Andrés Pantoja Bucheli

Editorial
Universidad de Nariño

êditorial
Universidad de **Nariño**

JERARQUÍAS DE CONTROL EN MICRORREDES

Modelado Matemático y Algoritmos de Control

JERARQUÍAS DE CONTROL EN MICRORREDES

Modelado Matemático y Algoritmos de Control

Juan Gabriel Ordóñez Ordóñez
Harold Ruiz Bravo
Laura Rodríguez Rivera
Javier Revelo Fuelagán
Andrés Pantoja Bucheli

êditorial
Universidad de Nariño

Jerarquías de control en microrredes : modelado matemático y algoritmos de control / Juan Gabriel Ordóñez Ordóñez … [y otros] –1ª. ed. -- San Juan de Pasto : Editorial Universidad de Nariño, 2025

171 páginas: ilustraciones, tablas, gráficas

Incluye referencias bibliográficas p. 148 – 160 y reseña de los autores p. 168-169

ISBN: 978-628-7771-37-6

1. Ingeniería eléctrica 2. Microrredes 3. Energía eléctrica--Distribución 4. Generación fotovoltaica—Energía eléctrica 5. Algoritmos de control—Energía eléctrica 6. Energía eléctrica— Sistemas de control 7. Flujo óptimo de potencia 8. Energía eléctrica—Almacenamiento, consumo 9. Transmisión de potencia 10. Inversor fotovoltaico trifásico. I. Ordóñez Ordoñez, Juan Gabriel II. Ruiz Bravo, Harold Fernando III. Rodríguez Rivera, Laura María IV. Revelo Fuelagán, Javier V. Pantoja Bucheli, Andrés Darío

621.317 J55 – SCDD-Ed. 22

Universidad de Nariño FUNDADA EN 1904

Universidad de Nariño ACREDITADA EN ALTA CALIDAD RESOLUCIÓN MEN 000022 • ENERO 11 DE 2023

SECCIÓN DE BIBLIOTECA

JERARQUÍAS DE CONTROL EN MICRORREDES

Modelado Matemático y Algoritmos de Control

©Editorial Universidad de Nariño
©Juan Gabriel Ordóñez Ordóñez
Harold Ruiz Bravo
Laura Rodríguez Rivera
Javier Revelo Fuelagán
Andrés Pantoja Bucheli

ISBN: 978-628-7771-37-6
Primera Edición
Corrección de estilo: Christian Benavides Martínez
Diseño de portada: Liseth Motta Realpe
Fecha de publicación: Abril 2025
San Juan de Pasto, Nariño, Colombia

Prohibida la reproducción total o parcial, por cualquier medio o cualquier propósito, sin la autorización escrita de sus autores o de la Editorial de la Universidad de Nariño.

CONTENIDO

PRÓLOGO **10**

1 Control Primario:

Control de Potencia Activa y Reactiva de un Inversor Fotovoltaico Trifásico **12**

1.1 Resumen 12

1.2 Introducción 13

1.3 Diseño del Convertidor DC-DC 16

1.3.1 Formulación de la función de costo de un sistema fotovoltaico bajo condiciones de sombreado parcial 17

1.3.2 Cálculo de los parámetros del convertidor electrónico Boost 20

1.3.3 Estrategias hibridas de búsqueda del punto GMPP 22

1.3.4 Controlador por modos deslizantes 30

1.4 Diseño del Inversor 32

1.4.1 Modelo del Inversor NPC trifásico de dos niveles 33

1.4.2 Cálculo filtro LCL 34

1.4.3 Seguimiento de fase y frecuencia PLL 36

1.4.4 Controlador de potencia activa y reactiva del inversor trifásico 37

1.4.5 Generador de pulsos PWM 41

1.5 Implementación experimental 41

1.6 Resultados y discusión 43

1.6.1 Análisis de los controladores empleados en la etapa del convertidor DC/DC 43

1.6.2 Análisis comparativo de los resultados obtenidos en el inversor en la simulación basada en modelos matemáticos y en la plataforma de simulación de tiempo real OPAL-RT 51

1.7 Limitaciones y trabajo futuro 60
1.8 Conclusiones 60

2 Control Secundario:
Análisis comparativo de técnicas de control secundario 62
2.1 Resumen 62
2.2 Introducción 62
2.3 Modelo propuesto de la red aislada 65
2.3.1 Cálculo filtro LCL 65
2.3.2 Rastreo de fase y frecuencia PLL 67
2.3.3 Generador de pulsos PWM 67
2.3.4 Modelo de espacio de estados 68
2.3.5 Control Droop 69
2.3.6 Control primario 70
2.3.7 Control secundario 72
2.4 Controladores centralizados 73
2.4.1 Control tipo PI de Ebrahim 73
2.4.2 Control MRAC 73
2.5 Controladores Distribuidos 76
2.5.1 Sin control de potencia reactiva 76
2.5.2 Con control de potencia reactiva 78
2.6 Sintonización y entrenamiento de controladores 83
2.6.1 Entrenamiento del control MRAC 84
2.6.2 Método heurístico 87
2.6.3 Particle Swarm Optimization and Differential Evaluation (DEPSO) 88
2.7 Resultados y discusión 90
2.7.1 Microrred de prueba 90
2.7.2 Simulación en tiempo real 91
2.7.3 Escenarios de prueba y resultados en Simulink 92
2.7.4 Resultados en tiempo real 99
2.8 Limitaciones y trabajo futuro 103
2.9 Conclusiones 103

3 Control terciario:

Controladores predictivos para el flujo óptimo de potencia 105

3.1 Resumen 105

3.2 Introducción 106

3.3 MPC centralizado para el flujo óptimo de potencia.....108

3.3.1 Despacho económico de potencia activa 108

3.3.2 Modelo predictivo.....110

3.3.3 Despacho de potencia reactiva - Modelo real 111

3.3.4 Despacho de potencia reactiva - Modelo fasorial 113

3.3.5 Algoritmo MPC para despacho secuencial 114

3.3.6 Algoritmo MPC para despacho unificado 114

3.3.7 Escenarios de simulación 116

3.3.8 Modelos de predicción 119

3.3.9 Resultados y discusión 121

3.4 MPC distribuido para el despacho óptimo de potencia activa 139

3.4.1 Resultados y discusión 142

3.5 Limitaciones y trabajo futuro 146

3.6 Conclusiones 146

BIBLIOGRAFÍA 148

Lista de Figuras 161

Lista de Tablas 167

Sobre los autores.....168

AGRADECIMIENTO

Los autores expresamos nuestro agradecimiento por la realización de este libro de investigación al proyecto titulado ”DESARROLLO DE UN MODELO ALTERNATIVO DE ENERGÍA Y MOVILIDAD CON FUENTES NO CONVENCIONALES EN LA UNIVERSIDAD DE NARIÑO”, identificado con el código BPIN 2020000100041. Este proyecto fue financiado por el Fondo de Ciencia, Tecnología e Innovación (CTeI) del Sistema General de Regalías (SGR) y MINCIENCIAS, en el marco de la convocatoria 890 - 2019 ”FORTALECIMIENTO DE CAPACIDADES INSTITUCIONALES - INVESTIGACIÓN IES PÚBLICAS - MECANISMO DE PARTICIPACIÓN 1”. Por último, queremos expresar nuestro agradecimiento a la Universidad de Nariño en calidad de entidad ejecutora del proyecto, con la participación del Grupo de Investigación en Ingeniería Eléctrica y Electrónica (GIIEE), así como a la Universidad del Valle, en calidad de entidad aliada, con la participación del Grupo de Investigación en Transporte, Tránsito y Vías (GITTV) y del Grupo de Investigación en Percepción y Sistemas Inteligentes (PSI).

PRÓLOGO

En la actualidad, en Colombia se está promoviendo activamente la transición energética. Dentro de las estrategias para llevar a cabo esta transición, se está explorando la implementación de comunidades energéticas con el fin de proporcionar soluciones sostenibles y descentralizadas en el suministro de energía. Esta iniciativa también se presenta como una alternativa viable para extender el servicio de energía a las zonas no interconectadas del territorio nacional.

Dentro del contexto de las comunidades energéticas, las microrredes desempeñan un papel fundamental al permitir la gestión localizada de la generación, la distribución, el almacenamiento y el consumo de energía. Esto implica que las comunidades pueden lograr cierto grado de independencia energética, empleando fuentes de energía renovable y sistemas de almacenamiento para satisfacer sus necesidades.

Debido a lo anterior, las microrredes se presentan como una solución eficiente a los problemas derivados del ámbito energético. Estos sistemas operan de manera controlada, aprovechando el registro de mediciones, la aplicación de algoritmos de control y la acción de los actuadores. Los algoritmos de control son los encargados de tomar decisiones que contribuyan al logro de los objetivos de control, como el seguimiento de potencia, la regulación de la tensión, la regulación de la frecuencia, entre otros. Entre los actuadores principales de las microrredes se encuentran los convertidores electrónicos de potencia, que se convierten en la interfaz de conexión de los diferentes elementos de la microrred, como

los generadores de energía renovable, los sistemas de almacenamiento de energía y las diferentes cargas que componen la microrred.

En este contexto, el primer capítulo de este libro se enfoca en el diseño e implementación de un inversor trifásico en un simulador en tiempo real, que es capaz de gestionar la inyección de potencia activa y reactiva a la red eléctrica, con el propósito de mejorar la eficiencia de los sistemas de generación fotovoltaica, especialmente bajo condiciones de sombreado parcial.

El segundo capítulo se centra en el control secundario, esencial para garantizar la estabilidad, eficiencia y confiabilidad de las microrredes. Actúa como un nivel de supervisión y optimización por encima del control primario, mejorando la calidad de la tensión y la frecuencia. Esto contribuye a la mejora de la calidad de la energía, la resiliencia ante fallos y la capacidad de integrar fuentes de energía renovable. Además, se presenta el análisis del rendimiento de estructuras de control tanto centralizadas como distribuidas en microrredes.

El tercer capítulo presenta modelos de optimización y algoritmos diseñados para mejorar el rendimiento de la gestión energética ante la presencia de incertidumbre. El contenido se centra en el flujo óptimo de potencia (FOP) mediante un enfoque de control predictivo por modelo (MPC), la incorporación de modelos de predicción de generación renovable y dinámicas de consumo, e introduce un modelo de optimización y un algoritmo distribuido para el despacho óptimo de potencia activa.

Finalmente, este libro de investigación presenta los resultados parciales del proyecto denominado “DESARROLLO DE UN MODELO ALTERNATIVO DE ENERGÍA Y MOVILIDAD CON FUENTES NO CONVENCIONALES EN LA UNIVERSIDAD DE NARIÑO”, identificado con BPIN 2020000100041, que tuvo como objetivo general, desarrollar estrategias de movilidad y energía con fuentes no convencionales en un esquema integral de gestión de información en la Universidad de Nariño. En particular, se presentan los resultados de las aplicaciones de los modelos matemáticos y los algoritmos de control de las microrredes, dando cumplimiento a uno de los objetivos específicos del proyecto de investigación, enfocado a fortalecer los sistemas de generación con fuentes no convencionales de energía integrados a la microrred de la Universidad de Nariño.

CAPÍTULO 1

CONTROL PRIMARIO: CONTROL DE POTENCIA ACTIVA Y REACTIVA DE UN INVERSOR FOTOVOLTAICO TRIFÁSICO

1.1 Resumen

Las microrredes eléctricas se han propuesto como método para facilitar la transición energética, aprovechando al máximo los recursos renovables mediante la integración de sistemas de generación distribuida. Así, el aprovechamiento del recurso solar no solo debe enfocarse en la construcción de paneles solares más eficientes, sino también, en el desarrollo de controladores de inversores que posibiliten mitigar los efectos negativos generados por las condiciones de sombreado parcial (PSC). Adicionalmente, en presencia de cargas que demandan potencia reactiva, el inversor debe realizar la debida compensación. Por lo anterior, en este capítulo se presenta el diseño e implementación de un inversor solar trifásico conectado a la red, el cual disminuye el efecto de las PSC y controla la inyección de potencia activa y reactiva a la red eléctrica. Para esto, en la etapa DC del inversor se elaboraron y compararon siete algoritmos MPPT híbridos que convergen al punto de máxima potencia global y un controlador por superficie de deslizamiento que controla la corriente que circula por el convertidor DC/DC. Adicionalmente, en la etapa AC se realizaron tres controladores que posibilitan la regulación de la potencia activa y reactiva. El inversor se evalúa mediante simulaciones basadas en modelos matemáticos y en una plataforma de simulación en tiempo real Opal-RT, con el fin de analizar errores estándar, métricas de factor de seguimiento y la potencia media seguida en la validación de la etapa DC. Por su parte, en la etapa AC se

analizó la eficiencia del inversor, la capacidad de despacho de potencia reactiva y el correcto balance de potencias presentes en el sistema. Finalmente, el inversor se transforma en una alternativa para corregir el factor de potencia.

1.2 Introducción

Las microrredes eléctricas se han propuesto como una forma de abordar la transición energética maximizando la eficiencia de los recursos renovables [1], [2]. En Colombia uno de los generadores distribuidos con el mayor potencial son los sistemas fotovoltaicos, puesto que constituye una fuente estable para el aprovechamiento en generación de energía eléctrica, tanto en áreas aisladas como conectadas al sistema de interconexión nacional (SIN), cuyo recurso de irradiación solar diaria promedio es un 15,39 % más alto que el valor promedio mundial [3].

En este contexto, es importante fomentar, planificar y llevar a cabo la instalación de microrredes eléctricas que incluyan sistemas fotovoltaicos, debido a las condiciones climáticas favorables y a las ventajas fiscales proporcionadas por la normativa vigente por el uso de estas fuentes no convencionales de energía renovable. Por lo anterior, es crucial mejorar el desempeño de los sistemas fotovoltaicos, los cuales se ven afectados principalmente por la eficiencia de los paneles solares y la etapa de conversión de potencia con su técnica de seguimiento del punto de máxima potencia (MPPT - *Maximum Power Point Tracking*).

En la actualidad, muchos de los controladores solares MPPT comerciales no logran encontrar el punto de máxima potencia global (GMPP) en sistemas fotovoltaicos bajo condiciones de sombreado parcial (PSC - *Partial shading conditions*). Como resultado, se producen pérdidas significativas de potencia activa en la microrred, lo que conlleva efectos negativos como un mayor costo en la facturación eléctrica, menor eficiencia energética, menor aprovechamiento del suministro energético y un aumento en la temperatura del módulo fotovoltaico. Adicionalmente, en presencia de cargas que necesitan potencia reactiva, algunos inversores fallan en compensar adecuadamente esta potencia, causando inconvenientes en la microrred, como altas corrientes y fluctuaciones en el nivel de tensión, que pueden exigir la incorporación de generadores distribuidos para ser balanceadas. Por tanto, es esencial contar con sistemas MPPT eficaces que permitan utilizar completamente la energía generada por el sistema fotovoltaico, junto con un control del inversor bien sintonizado que pueda inyectar potencia activa y reactiva a la red eléctrica de manera eficiente.

Numerosos estudios se han centrado en desarrollar técnicas de seguimiento MPPT que logran alcanzar el GMPP en sistemas fotovoltaicos que operan bajo PSC. En [4] se utiliza un controlador de lógica difusa (FLC - *Fuzzy Logic Controller*) y una red neuronal artificial (ANNs - *Artificial Neural Neworks*) para encontrar el punto GMPP en un sistema fotovoltaico usando la temperatura y la irradiancia en el proceso de entrenamiento de la ANN.

De igual forma, se han propuesto técnicas bioinspiradas híbridas capaces de encontrar el punto GMPP. Estos algoritmos se caracterizan por combinar una técnica de optimización

evolutiva con un método convencional de seguimiento MPPT, como perturbar y observar (P&O - *Perturb and Observe*) o conductancia incremental (IC-*Incremental Conductance*) [5]. Por su parte, PSO (*Particle Swarm Optimization*) es una de las técnicas evolutivas más populares en la literatura [6]-[9] debido a sus capacidades al momento de solucionar funciones estocásticas. Sin embargo, la forma estándar de esta técnica presenta varios inconvenientes, como velocidad constante de la partícula, alta dependencia a los parámetros de calibración, baja velocidad de convergencia y, en algunos casos, alto costo computacional. Por ello, en otros estudios se ha utilizado modificaciones al algoritmo PSO que resuelven estas problemáticas. En [10], se implementa un algoritmo basado en la combinación de un PSO convencional y la técnica de Evaluación diferencial (DE), con el fin de resolver las problemáticas típicas generadas por las PSC. Cabe resaltar que las características principales del método MPPT híbrido son la compensación de las deficiencias que tienen los algoritmos DE y PSO por separado, su simplicidad y rapidez.

En otros estudios se han utilizado otros métodos, como en [11], que usa el algoritmo de optimización de lobos grises (GWO - *Grey Wolf Optimization*) para un sistema fotovoltaico trifásico de dos etapas capaz de encontrar el punto GMPP. Igualmente, en [12], se presenta una modificación del algoritmo (ABC - *Artificial Bee Colony*) para el seguimiento del punto de máxima potencia (MPPT), cuyo rendimiento se compara con el algoritmo PSO en condiciones climáticas dinámicas.

Adicionalmente, se han desarrollado técnicas de optimización que posibilitan disminuir los efectos negativos de las PSC y mejorar el rendimiento computacional, como el desarrollado en [13], donde se implementa una técnica rápida y eficiente basada en la Optimización del Movimiento Radial (RMO) para detectar el GMPP en PSC. Además, se examina su rendimiento comparándola con la técnica PSO, la cual considera tres factores: la velocidad de convergencia, la estabilidad y el costo computacional. Igualmente, en [14] se propone una modificación al algoritmo RMO denominado (ARMO - *Adaptive Radial Movement Optimization*), que se compara con métodos MPPT convencionales consiguiendo una alta eficiencia y confiabilidad en el seguimiento del GMPP en PSC.

De igual forma, se ha desarrollado y probado técnicas híbridas mediante el uso de herramientas que posibilitan reducir la brecha existente entre la simulación y el controlador real, como el implementado en [15], donde se presenta una nueva técnica MPPT híbrida que combina el ajuste polinomial basado en superficie (SFP) y el regulador convencional MPPT (P&O) para la generación de energía bajo PSC. Es importante señalar que el desarrollo experimental se elabora en un simulador en tiempo real y de alta velocidad (PLECS RT Box). Asímismo, en [16] se implementa un algoritmo basado en el método (CSA - *Cukoo Search Algorithm*) para abordar las PSC que presentan los MPPT tradicionales, resaltando que la validación experimental se realizó mediante un simulador de Hardware-In-the-Loop (HIL) en tiempo real (OPAL-RT OP4510) y un dSPACE 1104.

Además, con relación al inversor de inyección a la red, son indispensables varios lazos de control que acoplen el generador distribuido con la red eléctrica. Al respecto, la bibliografía presenta varias investigaciones que explican diferentes controladores que posibilitan un adecuado despacho de potencia activa y reactiva a la red. En particular, el trabajo en [17],

implementa un inversor de fuente de corriente (CSI - *Current source inverter*) en un sistema fotovoltaico conectado a la red. El CSI se regula mediante un controlador PI multi-bucle que permite la inyección de potencia activa y reactiva a la red, con el cual se obtienen corrientes de salida sinusoidales equilibradas con un límite armónico aceptable.

Por otra parte, en [18] se detalla dos técnicas PI para el control de la potencia activa y reactiva de un generador distribuido trifásico, destacando que el segundo controlador PI se sintoniza mediante el método heurístico ABC. Los resultados muestran la eficacia del ajuste de los parámetros de PI mediante ABC.

De igual forma, en [19] se presentan los resultados de simulación de un inversor CSI de inyección a la red implementado en Matlab. El microinversor de 1000 W consta de cuatro convertidores DC-DC flyback intercalados, con su respectivo rastreador MPPT basado en el algoritmo P&O y un circuito armónico de inyección de tercer armónico activo que posibilita el control de la potencia reactiva, cuya eficiencia es de 95,07 %. Asímismo, en [20] se implementa en el sotfware Matlab-Simulink un sistema trifásico conectado a la red con control de potencia reactiva para regular el voltaje y mejorar el factor de potencia del sistema. El sistema de control del inversor posibilita la adecuada compensación de la potencia reactiva en la red eléctrica en diferentes condiciones de operación.

En otras investigaciones se han empleado métodos adaptativos, como en [21], en el que se utiliza un método variable y adaptativo de perturbación y observación (P&O) con control predictivo en un sistemas de generación fotovoltaica (PV) trifásicos de tres niveles con punto neutro fijo (NPC). El rendimiento del método propuesto fue probado y comparado con el algoritmo MPPT de perturbación fija en diferentes condiciones. Por otra parte, en [22] se desarrolla un método de control predictivo de potencia directa (PDPC) basado en el enfoque de la función de Lyapunov para el control de un convertidor fotovoltaico (PV) conectado a la red. La simulación muestra que la estrategia de control mantiene las potencias activa y reactiva cerca de los valores deseados bajo diferentes modos de operación.

Por otra parte, existen trabajos que se han implementado en plataformas de simulación en tiempo real, como en [23], en el que se desarrolla una estrategia de regulación basada en un controlador de banda de histéresis adaptativa (HBC) en un sistema PV conectado a la red en el simulador en tiempo real, OPAL-RT, OP5600, el cual mejora el rendimiento del sistema, en varios modos de funcionamiento.

Después de analizar el estado de arte, se encontró que la implementación de un sistema fotovoltaico de inyección a red bajo PSC y con capacidad de controlar la potencia reactiva ha sido poco estudiada en la literatura de forma conjunta (convertidor-inversor). Asimismo, en la mayoría de los documentos consultados con respecto a la mitigación de las PSC, la comparación de los algoritmos MPPT propuestos se realiza solamente con uno o dos métodos adicionales. Por lo anterior, este capítulo introduce la implementación de un inversor de inyección a la red en su totalidad, que es capaz de disminuir las PSC y gestionar la potencia reactiva inyectada a la red. El inversor en sus diferentes etapas se modela utilizando el software Matlab y la plataforma de simulación de tiempo real OPAL-RT. El análisis se elabora por etapas de conversión de potencia, empezando por el convertidor DC/DC y posteriormente por el inversor DC/AC.

Los principales aspectos abordados en este capítulo son:

- Un analisis detallado de los algoritmos híbridos RMO-CI [13], ARMO-CI [14], ABC-CI [12], GWO-CI [11], PSO-CI [10], CSA-CI [16] y WPSO-CI [10] en un inversor de inyección a la red bajo PSC.
- El diseño de un controlador por modos deslizantes que regula la corriente y el voltaje en el convertidor DC/DC, que es robusto a perturbaciones.
- Para la validación de los controladores GMPPT propuestos, se presentan dos escenarios diferentes de patrones de sombra que combinan variaciones de irradiancia uniforme, cambios bruscos de las PSC y múltiples picos en la curva característica PV.
- El diseño de un controlador PI, PI resonante y por banda de Histéresis que regule la corriente en el inversor trifásico, además de garantizar la sincronización con la red eléctrica y la inyección de potencia activa y reactiva.
- Los resultados en simulación en la etapa DC se evalúan utilizando errores estándar, puntuaciones de factor de seguimiento, potencia media rastreada y la correlación entre las señales de referencia y las obtenidas por cada algoritmo. Por otro lado, en la etapa AC se califica la capacidad de despacho de potencia reactiva, el seguimiento de la potencia activa y reactiva, así como el correcto balance de potencias del sistema.
- El diseño de modelos de celdas solares que presentan un buen desempeño en el entorno de simulación en tiempo real RT-LAB.
- La validación de los diferentes controladores en las etapas que componen el conjunto convertidor-inversor en la plataforma de simulación en tiempo real OPAL-RT.

1.3 Diseño del Convertidor DC-DC

El sistema considerado en esta investigación en su etapa DC se muestra en la Figura 1.1. Está compuesto por un arreglo de seis módulos fotovoltaicos conectados en serie (A), un convertidor DC/DC (B), un regulador GMPPT híbrido (C) y un controlador por superficie de deslizamiento (D). El convertidor DC/DC regula el voltaje del arreglo de paneles fotovoltaicos y está conformado por un capacitor de entrada (C_i), un inductor (L), un transistor IGBT (S), un diodo (D), un capacitor de salida (C_o) y una resistencia de carga (R). El esquema de control del convertidor se basa en un doble lazo de control. El lazo interno controla la corriente del inductor (I_L) a través del cambio en el ciclo de trabajo (d) y el lazo externo controla el voltaje del capacitor (V_{in}) a través del cambio en la referencia de corriente. El voltaje de referencia viene dado por el método GMPPT híbrido que posibilita encontrar el punto GMPP en PSC.

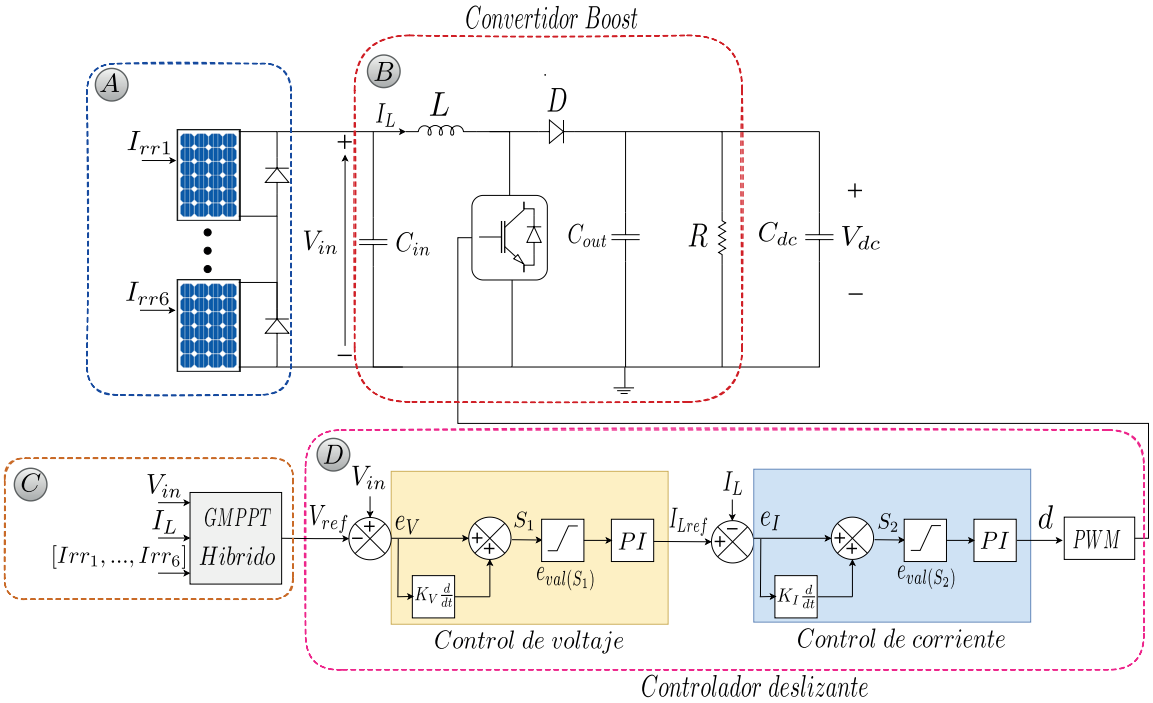

Figura 1.1: Diagrama del convertidor DC/DC

1.3.1 Formulación de la función de costo de un sistema fotovoltaico bajo condiciones de sombreado parcial

Una celda fotovoltaica, según [24], puede ser representada por un modelo equivalente mediante la ley de corrientes de Kirchhoff como:

$$I = I_{ph} - I_d - I_{sh}, \tag{1.1}$$

donde, la corriente del diodo es

$$I_d = I_0(e^{\frac{q(V_{PV}+I_{PV}R_s)}{(N_sAKT_{stc})}} - 1), \tag{1.2}$$

y la corriente de derivación

$$I_{sh} = \frac{(V_{PV} - I_{PV}R_sN_s)}{(R_sN_s)}, \tag{1.3}$$

y la corriente fotogenerada por el sol se puede definir con

$$I_{ph} = \frac{G}{Gstc}Istc. \tag{1.4}$$

Reemplazando (1.2), (1.3) y (1.4) en (3.1), resulta la siguiente expresión:

$$I_{PV} = \frac{G}{Gstc} Istc - I_0 \left(exp \left(\frac{q(V_{PV} + I_{PV} R_s)}{(N_s A K T_{stc})} \right) - 1 \right) - \frac{(V_{PV} - I_{PV} R_s N_s)}{(R_s N_s)}, \tag{1.5}$$

donde G es la irradiancia, I_{ph} es la corriente fotogenerada, I_{sh} es la corriente de derivación, R_{sh} es la resistencia de derivación, R_s es la resistencia en serie, I_{PV} es la corriente de la celda, V_{PV} es el voltaje de la celda, I_0 es la corriente de saturación del diodo, K es la constante de Boltzmann $(1.38 * 10^{-23} \frac{J}{K})$, q es la carga de electrones $(1.6 * 10^{-19}\ C)$, N_s es el número de celdas del módulo fotovoltaico, A representa el factor de idealidad del diodo, T_{stc} es la temperatura de funcionamiento (25°C), G_{stc} es la irradiancia en condición de prueba estándar $(1000 \frac{W}{m^2})$ y I_{stc} es la corriente fotogenerada bajo condición de prueba estándar. Los parámetros del PV utilizados se presentan en la Tabla 1.1.

Tabla 1.1: Parámetros de la celda fotovoltaica

Variable	Magnitud	Unidad de Medida
Resistencia en derivación de las celdas (R_{sh})	992.2435	Ω
Resistencia en serie de las celdas (R_s)	0.45891	Ω
Corriente de saturación del diodo (I_0)	1.7974×10^{-10}	A
Corriente fotogenerada (I_{stc})	9.5248	A
Corriente de cortocircuito (I_{sc})	9.39	A
Voltaje de circuito abierto (V_{oc})	45.48	V
Corriente en el punto de máxima potencia (I_{mp})	9.03	A
Voltaje en el punto de máxima potencia (V_{mp})	35.99	V
Número de celdas (N_{cell})	72	-
Factor de idealidad del diodo	0.99584	-

La ecuación (1.5) no permite modelar el efecto de los diodos bypass que se conecta en cada módulo fotovoltaico (Figura 1.2). Por su parte, los diodos de derivación cambian el comportamiento de los sistemas fotovoltaicos bajo cualquier PSC, por lo que los módulos no tienen los mismos valores de corriente y crean múltiples máximos en la salida PV.

En consecuencia, se supone que los diodos se pueden modelar matemáticamente como una resistencia [24], lo cual resulta en:

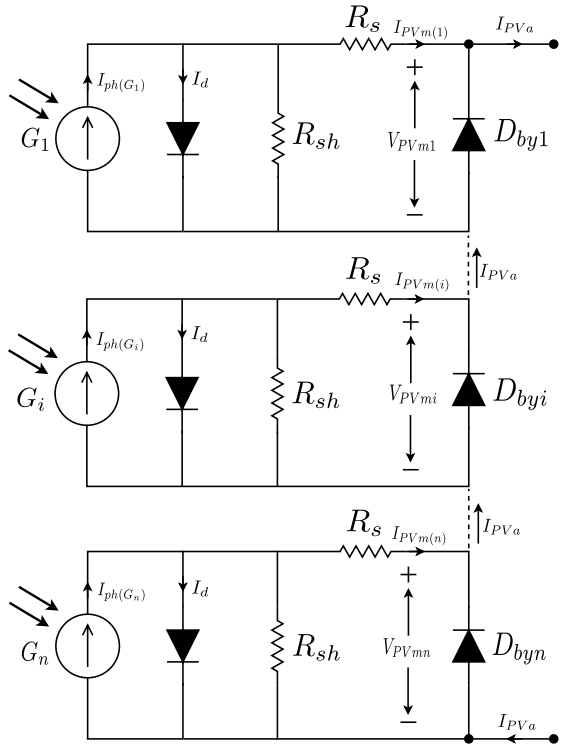

Figura 1.2: Modelo equivalente de k módulos PV, modificado de [24]

$$
\begin{aligned}
I_{PVa} =& I_{PVm(i)} \; si \; I_{PVa} > I_{ph(i)} \\
I_{PVm(i)} =& I_{ph}(G_i) - I_0 \left(exp \left(\frac{q(V_{PVm(i)} + I_{PVa} R_s)}{(N_s A K T_{stc})} \right) - 1 \right) \\
& - \frac{(V_{PVm(i)} - I_{PVa} R_s N_s)}{(R_s N_s)} \\
V_{PVa} =& \sum_{i=1}^{n} V_{PVm(i)},
\end{aligned}
\tag{1.6}
$$

donde $I_{ph(i)}$ es la corriente fotogenerada para i^{th} módulo, n es el número de módulos presentes en el sistema, I_{PVa} es la corriente medida en los terminales del sistema fotovoltaco y $V_{PVm(i)}$ e $I_{PVm(i)}$ son las salidas de voltaje y corriente del i^{th} módulo, respectivamente.

Una vez que se ha representado el impacto del diodo bypass, se procede con la formulación del problema de optimización para maximizar la potencia suministrada (o minimizar su negativo), obteniendo como resultado

$$
\begin{aligned}
\min_{F_{(I_{PVa}, V_{PVa}, G)}} \quad & -\textstyle\sum_{i=1}^{n} V_{PVm(i)} I_{PVa} \\
\text{s.t.} \quad & I_{PVa} = I_{PVm(i)} \\
& V_{PVa} = \textstyle\sum_{i=1}^{n} V_{PVm(i)}.
\end{aligned}
\tag{1.7}
$$

Sin embargo, resolver el problema de optimización expresado en (1.7) se vuelve complicado debido a la naturaleza altamente no lineal de la corriente en la celda. Para simplificar el problema, se utiliza una función de penalización como la mostrada en [25], donde las diferentes restricciones de desigualdad e igualdad pueden transformarse en la forma general. La función de penalización puede definirse como:

$$F(x) = f(I_{PVa}, V_{PVa}, G) + H(I_{PVa}, V_{PVa}, G), \tag{1.8}$$

donde $f(I_{PVa}, V_{PVa}, G) = -\sum_{i=1}^{n} V_{PVm(i)} I_{PVa}$ y $H(I_{PVa}, V_{PVa}, G)$ es un factor de penalización que es estrictamente positivo para todas las soluciones no factibles, de la cual se obtiene la expresión:

$$H(I_{PVa}, V_{PVa}, G) = \omega_1 NVC_x + \omega_2 SVC_x, \tag{1.9}$$

donde NVC_x es el número de restricciones violadas por la solución y SVC_x es la suma de todas las restricciones violadas, de lo cual se obtiene la ecuación:

$$\begin{aligned} SVC_x &= \sum_{i=1}^{m} g_i(I_{PVa}, V_{PVa}, G) \\ g_i(I_{PVa}, V_{PVa}, G) &= \begin{cases} V_{PVm(i)} + V_{bpd}, \ si \ I_{ph(i)} \leq I_{PVa} \\ I_{PVm(i)} - I_{PVa}, \ si \ I_{ph(i)} > I_{PVa} \end{cases}, \end{aligned} \tag{1.10}$$

donde, V_{bpd} es el voltaje de saturación del diodo bypass, ω_1 y ω_2 son ganancias estáticas que fueron sintonizadas mediante diversas pruebas en simulación, encontrando que $V_{bpd} = 0.5$, $\omega_1 = 10$ y $\omega_2 = 100$ respectivamente. El Algoritmo 1.1 resume el proceso de formulación del problema de optimización.

1.3.2 Cálculo de los parámetros del convertidor electrónico Boost

En los MPPT se utilizan convertidores de potencia, entre los que se encuentra el convertidor Boost. Este suele estar conectado al módulo fotovoltaico como fuente de entrada y funciona a través de los pulsos de conmutación producidos por el PWM, tal y cómo se puede observar en la Figura 1.1.

El diseño del convertidor de potencia se realiza para determinar la inductancia y la capacitancia utilizadas en el convertidor MPPT. La inductancia se calcula para mantener el regulador MPPT en el modo de corriente continua. Este modo es importante para que el controlador mantenga una salida estable. Si la inductancia es demasiado pequeña, el convertidor MPPT funcionará en el modo de corriente discontinua, mientras que, si la inductancia es demasiado grande, el controlador MPPT se vuelve más robusto, pero tendrá una respuesta transitoria lenta. La capacitancia se calcula para garantizar que el rizado de tensión se mantenga dentro de la especificación deseada. Si esta es demasiado pequeña, el rizado de tensión se vuelve grande; en el caso contrario, la respuesta transitoria del convertidor MPPT se volverá lenta.

Algoritmo 1.1 Función de costo de un sistema fotovoltaico bajo PSC

Entrada: $R_{sh}, R_s, I_0, K, q, N_s, A, V_{bpd}, I_{PVa}, V_{PVa}$
Salida: F_{obj}
$I_{ph} \leftarrow \left([\frac{G_1}{Gstc}Istc, \frac{G_2}{Gstc}Istc, ..., \frac{G_n}{Gstc}Istc]\right)$ Matriz de corrientes fotogeneradas
para $i = 1 : n$ **hacer**
  si $I_{ph(i)} \leq I_{PVa}$ **entonces**
    $f_{eq} \leftarrow V_{PVm(i)} + V_{bpd}$
  si no, si $I_{ph(i)} > I_{PVa}$ **entonces**
    $f_{eq} \leftarrow I_{PVm(i)} - I_{PVa}$
  fin si
fin para
$SVC \leftarrow \sum |f_{eq}(I_{PVa}, V_{PVa}, G)|$
$NVC \leftarrow \sum |f_{eq}(I_{PVa}, V_{PVa}, G)| < 0.1$
$F_{eq} \leftarrow 10NVC + 100SVC$
$f_{obj} \leftarrow -\sum_{i=1}^{n} V_{PVm(i)}\, I_{PVa}$ Función de actitud original
$F_{obj} \leftarrow F_{eq} + f_{obj}$ Función de actitud final

Por lo anterior, en el presente trabajo se siguen las recomendaciones de [26] y se establecen dos puntos de máxima potencia, para establecer un rango de operación adecuado que posibilita encontrar el valor de la resistencia de salida R:

$$R_{mp} = \frac{V_{mp}}{I_{mp}}, \tag{1.11}$$

$$\frac{R_{mp(max)}}{(1 - D_{min})^2} \leq R \leq \frac{R_{mp(min)}}{(1 - D_{max})^2}, \tag{1.12}$$

donde R_{mp} es la resistencia máxima del punto de máxima potencia, f es la frecuencia de conmutación del transistor, V_{mp} e I_{mp} son el voltaje y la corriente máximas en el punto de máxima potencia, y D_{max} y D_{min} son el mínimo y máximo ciclo de trabajo deseado.

Como siguiente paso, se calcula la inductancia mínima del Boost:

$$L_{min} = \frac{4R}{27\gamma_{Lf}}, \tag{1.13}$$

Luego, se calcula el capacitor de entrada y salida del Boost mediante las siguientes expresiones:

$$C_{i_{min}} = 1 - \frac{\sqrt{\frac{R_{mp(min)}}{R^3}}}{8L\gamma_{Vmp}f^2}, \tag{1.14}$$

$$C_{o_{min}} = \frac{1}{\gamma_{Vo}f}\frac{1}{R} - \frac{1}{\gamma_{Vo}f}\sqrt{\frac{R_{mp(max)}}{R^3}}, \tag{1.15}$$

donde $\gamma_{V_{mp}}$ y γ_{V_o} son el factor de ondulación del voltaje en el punto de máxima potencia y del voltaje de salida, respectivamente.

Teniendo en cuenta las ecuaciones (1.12), (1.13), (1.14), (1.15) y suponiendo $\gamma_{Lf} = 0.15$, $\gamma_{V_{mp}} = 0.01$, $\gamma_{V_o} = 0.01$, $D_{\,min} = 0.1$ y $D_{\,max} = 0.6$, se obtienen los valores de $R = 153.9469$, $C_i = 5.4566 * 10^{-6}$, $L = 0.0152$ y $C_o = 4.3114 * 10^{-6}$.

Finalmente, al momento de integrar el convertidor DC/DC con el inversor, se debe retirar la resistencia de carga R, ya que se desea que toda la potencia se transfiera al inversor trifásico.

1.3.3 Estrategias híbridas de búsqueda del punto GMPP

La característica más significativa del algoritmo MPPT radica en su capacidad para reconocer el punto de máxima potencia bajo condiciones de irradiación uniforme como de sombreado parcial. En consecuencia, los algoritmos heurísticos usados en esta investigación son los métodos *Grey Wolf Optimization* (GWO), *Particle Swarm Optimization* (PSO), *Particle Swarm Optimization and Differential Evaluation* (DEPSO o wPSO), *Cuckoo's Search Algorithm (CSA)*, *Artificial Bee Colony Algorithm* (ABC), *Radial Movement Optimization* (RMO) y *Adaptative Radial Movement Optimization* (ARMO). Cabe señalar que todos los algoritmos son híbridos y se combinan con el algoritmo MPPT conductancia incremental (CI), con el fin de mejorar la convergencia al GMPP.

1.3.3.1 Método de conductancia incremental (CI): Este algoritmo compara la conductancia incremental con la conductancia instantánea en un sistema fotovoltaico. En función del resultado, ajusta la tensión incrementándola o reduciéndola hasta alcanzar el punto de máxima potencia (MPP). Al contrario del algoritmo de perturbar y observar (P&O), la tensión permanece constante una vez alcanzado el MPP [5], [6]. Sin embargo, la forma estándar de este algoritmo no puede ser fácilmente incorporada con las técnicas heurísticas utilizadas, por lo que es necesario modificar la estructura general del algoritmo CI para facilitar su unión. Dicha variación se detalla en el Algoritmo 1.2.

1.3.3.2 Cuckoo's Search Algorithm (CSA): Este algoritmo usa tres reglas basadas en el comportamiento parasitario del cuco: (1) cada cuco pone un huevo a la vez y lo coloca en un nido elegido al azar, (2) el mejor nido con alta calidad de huevos pasará a la siguiente generación y (3) el número de nidos disponibles es fijo y el huevo puesto por un cuco es descubierto por el ave anfitriona con una probabilidad P_a, donde $0 < P_a < 1$. Si los huevos del cuco son descubiertos, el ave anfitriona puede abandonar su nido o destruir los huevos del cuco. En cualquier caso, se generará un nuevo nido con una probabilidad P_a del número fijo de nidos [27]. Al generar una nueva solución $x(t+1)$ para un cuco, se realiza un vuelo Lévy que se define como:

$$x^{t+1} = x_i^t + \alpha \oplus Levy(\lambda), \tag{1.16}$$

Algoritmo 1.2 Algoritmo CI

Entrada: V_{in}, I_L, G
Salida: V_{ref}
$U_b \leftarrow [9.39\ 40\ 40\ 40\ 40\ 40\ 40]$ limite superior
$l_b \leftarrow [1\ -0.5\ -0.5\ -0.5\ -0.5\ -0.5\ -0.5]$ limite inferior
$Max_{iter} \leftarrow 1000$ iteraciones maximas
$dim \leftarrow 7$ dimesión
$pol \leftarrow 500$ población
$G_{prev} \leftarrow zeros[length(dim-1), 1]$
$V_{in_{prev}} \leftarrow 0$
$I_{L_{prev}} \leftarrow 0$
$V_{ref_{prev}} \leftarrow 0$
si $any(G_{prev} \sim= G\ or\ isempty(V_{ref_{prev}})$ **entonces**
  $F \leftarrow F_{obj}$ Función de actitud
  $G_{best} \leftarrow metodo_{GMPPT}(dim, pol, Max_{Iter}, U_b, l_b, F)$
  $V_{ref_{prev}} \leftarrow \sum G_{best}(2, end)$
  $V_{in_{prev}} \leftarrow V_{ref_{prev}}$
  $I_{L_{prev}} \leftarrow G_{best}(1)$
  $G_{prev} \leftarrow G$
fin si
$Delta \leftarrow 10^{-6}$ Paso algoritmo CI
$Delta_V \leftarrow V_{in} - V_{in_{prev}}$
$Delta_I \leftarrow I_L - I_{L_{prev}}$
si $Delta_V == 0$ **entonces**
  si $Delta_I \sim= 0$ **entonces**
    si $Delta_I > 0$ **entonces**
      $V_{ref} \leftarrow V_{ref} + Delta$
    si no, si $Delta_I \leq 0$ **entonces**
      $V_{ref} \leftarrow V_{ref} - Delta$
    fin si
  fin si
fin si
si $Delta_V \sim= 0$ **entonces**
  si $\frac{I_L}{V_{in}} + \frac{Delta_I}{Delta_V} \sim= 0$ **entonces**
    si $\frac{I_L}{V_{in}} + \frac{Delta_I}{Delta_V} > 0$ **entonces**
      $V_{ref} \leftarrow V_{ref} + Delta$
    si no, si $\frac{I_L}{V_{in}} + \frac{Delta_I}{Delta_V} \leq 0$ **entonces**
      $V_{ref} \leftarrow V_{ref} - Delta$
    fin si
  fin si
fin si
$V_{in_{prev}} \leftarrow V_{in}$
$I_{L_{prev}} \leftarrow I_L$
$V_{ref_{prev}} \leftarrow V_{ref}$

donde, $\alpha > 0$ es el tamaño del paso que está relacionado con la restricción del problema de optimización. Basado en las restricciones es importante ajustar el valor de α para obtener el tamaño de paso deseado. El producto $\oplus$ es el producto punto. El valor de $Levy(\lambda)$ se encuentra a partir de la distribución de levy dada por la siguiente expresión:

$$Levy(\lambda) \approx u = t^{\lambda} \quad (1 < \lambda < 3). \tag{1.17}$$

Después de comparar las nuevas soluciones, se escoge un nido al azar, y si la nueva solución es mejor, se remplaza esta por la nueva. Como siguiente paso, un porcentaje P_a de las peores soluciones se abandonan y se crean nuevas, como se detalla en [16].

1.3.3.3 Artificial Bee Colony Algorithm (ABC): El algoritmo ABC se basa en el comportamiento de las colonias de abejas [12], cuyas abejas artificiales se clasifican en tres grupos: abejas trabajadoras, abejas observadoras y exploradoras. Una abeja que está buscando comida o explotando una fuente de alimento se llama abeja empleada. Una abeja que espera en la colmena para tomar la decisión de elegir una fuente de alimento se denomina observadora. Las abejas empleadas cuyas fuentes de alimento no pueden ser mejoradas mediante un número predeterminado de ensayos se convierten en exploradoras, y sus fuentes de alimento son abandonadas. El número de fuentes de alimento es igual al número de abejas empleadas y también al número de abejas observadoras. Análogamente, en el contexto de la optimización, la posición de una fuente de alimento representa una solución candidata del problema de optimización, y la cantidad de néctar de una fuente de alimento corresponde a la calidad (*fitness*) de la solución asociada

$$x_i^j = x_{min}^j + \alpha(x_{max}^j - x_{min}^j), \tag{1.18}$$

donde x_{min}^j y x_{max}^j representan respectivamente el valor mínimo y el máximo de la variable de optimización, j y α son números aleatorios en el intervalo [0, 1].

Tras la inicialización de la población de abejas, la población de soluciones se somete a ciclos repetidos de los procesos de búsqueda de las abejas trabajadoras, las abejas observadoras y las abejas exploradoras. En cada ciclo, cada abeja trabajadora produce una nueva solución V_{ij} mediante (1.18) y luego evalúa su *fitness*

$$V_{ij} = \phi_{ij} + (x_{ij} - x_{kj}), \tag{1.19}$$

donde $k\epsilon\,[1, 2, \cdots, SN]$ y $j\epsilon\,[1, 2, \cdots, D]$ son índices escogidos de forma aleatoria, de tal forma que $j \neq k$. En cuanto a ϕ_{ij}, es un número aleatorio en el intervalo de $[-1, 1]$. Después de que las abejas trabajadoras compartan la información, cada abeja observadora encuentra la nueva solución V_{ij} dentro de la vecindad de x_i utilizando (1.18), basándose en la probabilidad P_i, definida como:

$$P_i = \phi_{ij} \frac{fitness_i}{\sum_{n=1}^{SN} fitness_n}. \tag{1.20}$$

La *fitness* de cada una produce una nueva solución V_{ij} que no está dentro del límite del espacio de búsqueda permitido, por lo cual se actualiza para que esté dentro de este espacio.

La *fitness* de cada nueva solución candidata producida V_{ij} se compara con la anterior, y si la nueva solución tiene una *fitness* igual o mejor, se sustituye en la memoria. En caso contrario, se mantiene la solución original. Al final de cada ciclo de búsqueda, si la *fitness* de una solución no puede mejorarse y se agota el número predeterminado de ensayos, la solución será abandonada por la abeja exploradora y se buscará una nueva solución al azar. La nueva solución x_i se generará utilizando (1.18). En [12] se presenta el diseño de seguimiento del punto MPPT para un PV utilizando ABC en PSC.

1.3.3.4 Grey Wolf Optimization (GWO): El algoritmo GWO imita la jerarquía de liderazgo y mecanismo de caza de lobos grises en la naturaleza propuesto en [28] . Se considera que los lobos grises están en la parte superior de la cadena alimentaria y se clasifican en cuatro tipos: alpha(α), beta (β), delta (δ) y omega (ω).

El comportamiento del algoritmo GWO se puede modelar mediante las siguientes expresiones:

$$\vec{D} = \left| \vec{C}.\vec{X}_P\left(t\right) - \vec{X}_P\left(t\right) \right|, \tag{1.21}$$

$$\vec{X}\left(t+1\right) = \vec{X}_P\left(t\right) - \vec{A}\ .\vec{D}, \tag{1.22}$$

donde t corresponde a la iteración actual, D, A y C denotan coeficientes vectoriales, X_P es el vector de posición de la presa y X indica el vector de posición del lobo gris. De igual forma, los vectores A y C se calculan mediante las ecuaciones:

$$\vec{A} = 2\vec{a}.\vec{r}_1 - \vec{a}, \tag{1.23}$$

$$\vec{C} = 2.\vec{r}_2, \tag{1.24}$$

donde los componentes de a disminuyen linealmente de 2 a 0 durante el curso de iteraciones y r_1, r_2 son vectores aleatorios en el intervalo [0, 1]. La búsqueda suele estar guiada por α, seguidos de β y δ, que también podrían participar ocasionalmente en la caza. Puntualizando que δ y ω se encargan de los lobos heridos de la manada. Por lo tanto, nos referimos a α como la solución candidata que tiene mejores conocimientos sobre la ubicación de la presa.

En [28] se presenta el diseño de seguimiento del punto MPPT para un PV usando el método GWO en PSC.

1.3.3.5 Particle Swarm Optimization (PSO): El método PSO es un enfoque metaheurístico sencillo y eficaz que se emplea en la optimización de funciones multivariables con múltiples óptimos locales. En este método, diversos agentes colaborativos intercambian información obtenida durante sus respectivos procesos de búsqueda. Cada agente se desplaza a través del espacio de búsqueda con una velocidad representada por V_i^k ,y dicho movimiento se determina mediante dos factores: 1) su mejor posición anterior y 2) la mejor posición alcanzada por cualquier agente en el conjunto. Según [6], [9], la velocidad y posición del agente se pueden expresar matemáticamente mediante las ecuaciones:

$$V_i^{k+1} = \omega V_i^k + c_1 r_1 P_{Best} + c_2 r_2 G_{Best}, \tag{1.25}$$

$$S_i^{k+1} = S_i^k + V_i^{k+1}, \tag{1.26}$$

$$P_{Best} = S_i^k, \tag{1.27}$$

$$f\left(S_i^k\right) > f\left(P_{Best}\right). \tag{1.28}$$

donde ω es el factor de aprendizaje, c_1 y c_2 son constantes positivas de calibración y r_1 y r_2 son números aleatorios normalizados en el rango [0,1]. La variable P_{Best} se utiliza para almacenar la mejor posición del i-ésimo agente encontrado hasta el momento (1.27) y su posición se actualiza si la condición (1.28) se cumple, f es la función objetivo que se maximiza en cada ciclo de iteración y G_{Best} es una variable que se utiliza para almacenar la mejor posición alcanzada entre los agentes. Se resalta que, en este proceso de optimización, el movimiento de los agentes se extiende por el espacio de búsqueda en diferentes direcciones.

1.3.3.6 Particle Swarm Optimization and Differential Evaluation (DEPSO o WPSO): En el algoritmo PSO, a medida que progresa el número de iteraciones, se observa una significativa disminución en la diversidad de partículas. Este fenómeno aumenta la probabilidad de quedar atrapado en los óptimos locales del espacio de soluciones. En contraste, el algoritmo DE tiene éxito explorando los óptimos locales del espacio de búsqueda mediante el uso de información diferencial; no obstante, este algoritmo compromete la calidad de su búsqueda para encontrar los óptimos globales. El algoritmo DEPSO aborda el problema de quedar atrapado en óptimos locales combinando el operador DE con el algoritmo PSO, esta combinación diversifica la técnica PSO [23]. En la literatura se ha demostrado que el algoritmo DEPSO supera a los algoritmos PSO y DE en términos de calidad de la solución y velocidad de convergencia. Los componentes clave en el proceso de búsqueda del algoritmo PSO son GBest y Pbest, donde cada individuo busca mejorar su posición para alcanzar GBest, la posición óptima encontrada por el enjambre. Sin embargo, la disminución ponderada de la velocidad de los individuos reduce la capacidad de diversificación del enjambre después de cierto número de iteraciones. La función del algoritmo DE en DEPSO es introducir diversidad al algoritmo PSO canónico y explorar de manera inteligente el espacio de búsqueda sin que los individuos queden atrapados en óptimos locales. Por lo tanto, el algoritmo PSO se aplica en cada iteración impar, mientras que el operador de mutación DE se implementa en las iteraciones pares. El Algoritmo 1.3 muestra la estructura general del algoritmo DEPSO (wPSO).

1.3.3.7 Radial Movement Optimization (RMO): Es una técnica de optimización estocástica basada en un enjambre. Tiene varias similitudes con otras técnicas evolutivas, como la evolución diferencial y PSO [13]. La técnica RMO comienza inicializando las partículas dentro del espacio de búsqueda del problema, donde cada partícula propone una solución al problema. La función de evaluación se llama función objetivo y calcula el valor de *fitness* de todas las partículas en cada paso. La generación de un vector de movimiento resultante depende de los dos mejores valores y de un vector aleatorio para las partículas.

Algoritmo 1.32 Algoritmo DEPSO (wPSO)

Entrada: $c_1, c_2, f, K, \omega, c_R, U_b, l_b, pol, dim, Max_{iter}$
Salida: G_{best}
$X \leftarrow lb + (Ub - lb) * rand(pol, dim)$
$P_{best} \leftarrow X$
$Fitness \leftarrow F(X)$ Se evalúa X en la Función de actitud detallada en el algoritmo 1.1.
$[F_{best}, Index] \leftarrow min(Fitness)$
$G_{best} \leftarrow X(Index, :)$
Algoritmo PSO
para $i = 1 : Max_{iter}$ **hacer**
$V \leftarrow \omega * V + c_1.*rand(pol, dim).*(P_{Best} - X) + c_2.*rand(pol, dim).*(G_{Best} - X)$

$X \leftarrow (X+V).*((X+V < U_b) \,\&\, (X+V > l_b)) + U_b.*((X+V > U_b) + l_b.*(X+V < l_b))$
$V \leftarrow V.*((X+V < U_b) \,\&\, (X+V > l_b)) + 0.*((X+V > U_b) \,\&\, (X+V < l_b))$
$Fitness_N \leftarrow F(X)$
$P_{best} \leftarrow P_{best}.*(Fitness \leq Fitness_N) + X.*(Fitness > Fitness_N)$
$Fitness \leftarrow Fitness.*(Fitness \leq Fitness_N) + Fitness_N.*(Fitness > Fitness_N)$

$[F_{best}, Index] \leftarrow min(Fitness)$
$G_{best} \leftarrow P_{best}(Index, :)$
Algoritmo DE
$target \leftarrow randi(pol, dim, 1)$
$r_1 \leftarrow randperm(pol, dim)$
$r_2 \leftarrow randperm(pol, dim)$
$r_3 \leftarrow randperm(pol, dim)$
$v \leftarrow X(target, :) + K.*(X(r_1, :) - X(target, :)) + f.*(X(r_2, :) - X(r_3, :))$
$aux \leftarrow rand(dim, 1).*ones(dim, dim)$
$u \leftarrow v.*(aux \leq C_R) + X(target, :).*(aux > C_R)$
$Fit \leftarrow F(u)$
$P_{best}(target, :) \leftarrow P_{best}(target, :).*(Fitness(target, :) \leq Fit) + u.*(Fitness(target, :) > Fit)$
$Fitness(target, :) \leftarrow Fitness(target, :).*(Fitness(target, :) \leq Fit) + Fit.*(Fitness(target, :) > Fit)$
$[F_{best}, Index] \leftarrow min(Fitness)$
$G_{best} \leftarrow P_{best}(Index, :)$
$X(target, :) \leftarrow u.*(Fitness(target, :) \leq Fit) + X(target, :).*(Fitness(target, :) > Fit)$
fin para

Las partículas del centro se dispersan a lo largo de los radios. Las partículas escapan en línea recta desde el centro en función del vector $V_{i,j}$ que se obtiene mediante las siguientes ecuaciones:

$$V_{i,j} = rand(0,1)V_{max(j)}, \tag{1.29}$$

$$V_{max(j)} = \frac{X_{max(j)} - X_{min(j)}}{k}, \tag{1.30}$$

donde k debe ser un número entero. Las pruebas realizadas en diferentes casos por [13] muestran que los mejores valores para k están dentro del rango de 2 a 5. No obstante, estos valores siguen dependiendo de otros parámetros. Para los casos de prueba, k se considera igual a 5. Normalmente, en estos métodos en los que se emplean partículas para buscar el espacio de soluciones, se define un peso de inercia para considerar el problema de la convergencia. El peso de inercia en RMO se muestra con W y se reduce en función del número de generaciones. La versión modificada de la ecuación (1.30) muestra la relación entre ω y la generación, y se encuentra definida por:

$$\omega_k = \omega_k \, rand(0,1)V_{max(j)}, \tag{1.31}$$

$$\omega_k = \omega_{max} - \frac{\omega_{max(j)} - \omega_{min(j)}}{Generation_{min}} \, Generation_k, \tag{1.32}$$

donde ω_{max} es igual a 1 y ω_{min} es igual a 0.

Se enfatiza que, a diferencia de PSO y DE, en el algoritmo RMO las partículas no sobrevuelan el espacio de solución. Por tanto, no es necesario guardar la ubicación actual de las partículas para el siguiente paso. Después de la dispersión, la función objetivo se utiliza para puntuar la *fitness* de las partículas y definir la mejor radial (R_{Best}), que es una partícula con el mejor valor de *fitness*. Esta ubicación junto con su valor de *fitness* se guarda en este paso. Otro valor importante es el mejor global (G_{Best}). Estos dos parámetros actualizan el centro paso a paso basándose en la expresión

$$\begin{aligned} Centre^{new} = & Centre^{old} + C_1 \left(G_{Best} - \ Centre^{old}\right) \\ & C_2 \left(R_{Best} - \ Centre^{old}\right), \end{aligned} \tag{1.33}$$

donde C_1, C_2 son los factores de coeficiente que deben fijarse para el optimizador antes de ejecutar el programa. Después de actualizar el punto central, la dispersión de las partículas comienza otra vez desde el nuevo centro. El valor del G_{Best} debe compararse con el R_{Best}. Si R_{Best} propone una solución mejor que G_{Best}, entonces la ubicación de G_{Best} debe intercambiarse con la de R_{Best}. El proceso continúa hasta que G_{Best} alcanza un valor definido o cuando el número de generación alcanza su valor máximo.

1.3.3.8 Adaptative Radial Movement Optimization (ARMO): El proceso operativo de ARMO es considerablemente similar al método RMO. Sin embargo, los coeficientes en ARMO cambian adaptativamente a lo largo del proceso del algoritmo. ARMO comienza el proceso de optimización dispersando múltiples partículas en el espacio de búsqueda predefinido. A continuación, las partículas dispersas se consideran soluciones propuestas y los valores de *fitness* de todas las partículas se calculan utilizando la función objetivo en cada paso del proceso de optimización. El vector de movimiento se determina mediante un vector aleatorio y los dos mejores valores de *fitness*. La principal diferencia entre ARMO y otros métodos de optimización según [14] es el estilo de movimiento de las partículas. En esta técnica, las partículas exploran el área definida alrededor del centro. En el Algoritmo 1.4 se detalla la estructura general del algoritmo ARMO.

Algoritmo 1.4 Algoritmo ARMO

Entrada: $c_{1max}, c_{2max}, c_{1min}, c_{2min}, W_{max}, W_{min}, K, U_b, l_b$
pol, dim, Max_{iter}
Salida: G_{best}
$V_{max} \leftarrow K * (U_b - l_b)$
$W_k \leftarrow rand()$
$W_{aux} \leftarrow (\frac{2}{Max_{iter}}) * (W_{max} - W_{min})$
$c_{1aux} \leftarrow (\frac{1}{Max_{iter}}) * (c_{1max} - c_{1min})$
$c_{2aux} \leftarrow (\frac{1}{Max_{iter}}) * (c_{2max} - c_{2min})$
$X \leftarrow lb + (Ub - lb). * rand(pol, dim)$
$F \leftarrow F(X)$ Se evalúa X en la Función de actitud detallada en el algoritmo 1.1.
$[F_{best}, Index] \leftarrow min(F)$
$Centro \leftarrow X(Index, :)$
$G_{best} \leftarrow Centro$
para $i = 1 : Max_{iter}$ **hacer**
$W_k \leftarrow W_k. * (i \leq 10) + (W_{max} - W_{aux} * i). * (i > 10)$
$V \leftarrow W_k * V_{max}. * rand(pol, dim)$
$X \leftarrow Centro + V$
$[F_{bestI}, Index] \leftarrow min(F)$
$R_{best} \leftarrow X(Index, :)$
$G_{best} \leftarrow G_{best}. * (F_{bestI} \geq F_{best}) + X(Index, :). * (F_{bestI} < F_{best})$
$c_{1k} \leftarrow c_{1min} + c_{1aux} * i$
$c_{2k} \leftarrow c_{2max} + c_{2aux} * i$
$centro \leftarrow centro + c_{1k} * (G_{best} - centro) + c_{2k} * (R_{best} - centro)$
$F_{best} \leftarrow F_{bestI}. * (F_{bestI} < F_{best}) + F_{best}. * (F_{bestI} \geq F_{best})$
fin para

1.3.4 Controlador por modos deslizantes

Este controlador es el encargado de controlar la corriente y el voltaje que circula por el convertido DC/DC para que el sistema fotovoltaico siga la referencia de voltaje brindada por el método MPPT. Por lo anterior, un modelo equivalente lineal del convertidor tipo Boost se presenta en [29], donde se detalla un método para linealizar el PV en un punto de funcionamiento. Generalmente, el punto de operación se selecciona en el punto de máxima potencia, ya que se espera que el sistema funcione en este punto. El modelo lineal se describe mediante una línea recta tangente a la curva I-V del PV en el punto de operación. Los controladores convencionales de modo deslizante operan a una frecuencia de conmutación muy alta y variable, lo que puede provocar un aumento de las pérdidas de conmutación e interferencias por ruido electromagnético. Por ello, en esta investigación se utiliza un controlador de modo deslizante basado en un controlador PI (SMPI), que se caracteriza por operar con una frecuencia de conmutación constante. En este controlador existen dos pasos esenciales. El primero es la definición de la superficie de deslizamiento y el segundo es el diseño de la ley de control. La superficie de deslizamiento se define en función de los objetivos de control del sistema [29]. Entonces, los objetivos de control para el sistema estudiado están relacionados con el error entre la variable medida y la referencia, ya que el esquema de control pretende reducir el error a cero. Por ello, la superficie de deslizamiento se define a través del error de tensión (e_v) y el error de corriente (e_i) definidos como:

$$e_v = V_{in} - V_{ref}, \tag{1.34}$$

$$e_I = I_{ref} - I_L. \tag{1.35}$$

Aunque para aumentar la respuesta dinámica del controlador a los errores definidos en las ecuaciones (1.34) y (2.46) se añaden sus derivadas, obteniendo el conjunto de superficies de deslizamiento *S*, dados por la expresión:

$$S = \begin{bmatrix} S_1 \\ S_2 \end{bmatrix} = \begin{bmatrix} e_v + k_v \frac{de_v}{d_t} \\ e_i + k_i \frac{di_v}{d_t} \end{bmatrix}. \tag{1.36}$$

Una vez determinadas las superficies de deslizamiento, el siguiente paso consiste en definir la ley de control que conduce las trayectorias del sistema hacia la superficie de deslizamiento y garantizar su permanencia en ella.

La trayectoria S se conmuta a través de la función $eval(s)$, donde esta función, según [29], se encarga de determinar la reacción del sistema ante cambios en las variables de estado. Para implementar la función $eval$, se utiliza una función lineal con saturación, que opera limitando la superficie cuando alcanza uno de sus valores máximos o mínimos y además, debido a su naturaleza lineal, es sensible a la reducción del ripple cuando el estado se aproxima a la superficie de conmutación.

Para definir la fase inicial del controlador, se utiliza un controlador proporcional-integral (PI). Esta fase inicial se caracteriza por los estados del sistema que aún no han alcanzado la superficie de deslizamiento. Las ganancias del controlador PI deben seleccionarse

adecuadamente de forma que exista un equilibrio entre la respuesta transitoria y la baja oscilación. Así, un valor alto de la ganancia proporcional aumentará las oscilaciones en el estado transitorio, mientras que un valor alto de la ganancia integral podría generar una respuesta casi lineal. El controlador PI añadido al control de modos deslizantes reduce el efecto *chattering*, presente en los controladores de modos deslizantes que se caracteriza por introducir vibraciones de alta frecuencia en el sistema, causadas principalmente por la alta frecuencia de conmutación [29]. De este modo, el controlador funciona con una frecuencia de conmutación constante. Las leyes de control para los dos lazos se pueden expresar como:

$$i_L = (k_{pv} + \frac{kiv}{s})\, eval(S_1), \tag{1.37}$$

$$d = (k_{pc} + \frac{kic}{s})\, eval(S_2). \tag{1.38}$$

donde k_{pv}, k_{iv}, k_{pc} y k_{ic} son las ganancias de los controladores proporcional integral (PI) de voltaje y corriente, respectivamente, S_1 y S_2 se presentan en la ecuación (1.36).

Definida la estructura del controlador, se procede a calibrar los parámetros que hacen parte del controlador por modos deslizantes, para lo cual se sigue las recomendaciones de [29] y se establece la siguiente función de costo:

$$\begin{aligned} ITAE_i &= \int_0^\tau t|e_i(t)|\, dt = \int_0^\tau t|i_{ref} - i_L|\, dt \\ ITAE_v &= \int_0^\tau t|e_v(t)|\, dt = \int_0^\tau t|v_{in} - v_{ref}|\, dt \\ ISE &= \int_0^\tau e_i^2(t)\, dt = \int_0^\tau (i_{ref} - i_L)^2\, dt, \end{aligned} \tag{1.39}$$

$$\begin{aligned} \min_{\bar{w}} \quad & ITAE_i \\ \text{s.t.} \quad & M_p < 10\,\%, \end{aligned} \tag{1.40}$$

$$\begin{aligned} \min_{\bar{w}} \quad & ITAE_v, ISE \\ \text{s.t.} \quad & M_p < 10\,\%, \end{aligned} \tag{1.41}$$

donde M_p es el sobrepaso máximo deseado en el controlador y $\bar{w}$ son los parámetros que se desean calibrar en el controlador.

Una vez definida la función de costo se procede a encontrar los parámetros mencionados en (1.37) y (1.38) que se calculan mediante el método heurístico PSO. La Figura 1.1 muestra el esquema del controlador propuesto, donde se especifican las superficies de deslizamiento, los controladores PI y las funciones eval. Destacando que para la presente investigación $k_{pv} = 775.193$, $k_{iv} = 156.46$, $k_{pc} = 731.97$, $k_{ic} = 24.02$, $K_V = 9.77 * 10^-5$, $K_I = 7.52 * 10^-6$, $eval(s_1) = [lim_s = 0.47, lim_i = -0.38]$ y $eval(s_2) = [lim_s = 0.23, lim_i = -0.34]$.

1.4 Diseño del Inversor

El sistema considerado en esta investigación en su etapa DC/AC se muestra en la Figura 1.3. El inversor está compuesto por un capacitador de acople (C_{out}), un conjunto de seis transistores IGBT (A), un filtro LCL (B) compuesto por 3 inductores (L_1), 3 capacitores (C_1) y 3 inductores (L_2), un controlador PLL (C), la carga trifásica y la red eléctrica, resaltando que el filtro y la carga van conectadas a la misma tierra física. Este convertidor utiliza un doble lazo de control (D) y un generador de pulsos PWM (E). El lazo interno del controlador regula la corriente que pasa por los inductores (L_2) mediante la activación y desactivación de los transistores IGBT. Mientras el lazo externo brinda las referencias de corriente teniendo en cuenta la potencia activa y reactiva que se desea inyectar. Los parámetros del inversor se muestran en la Tabla 1.2.

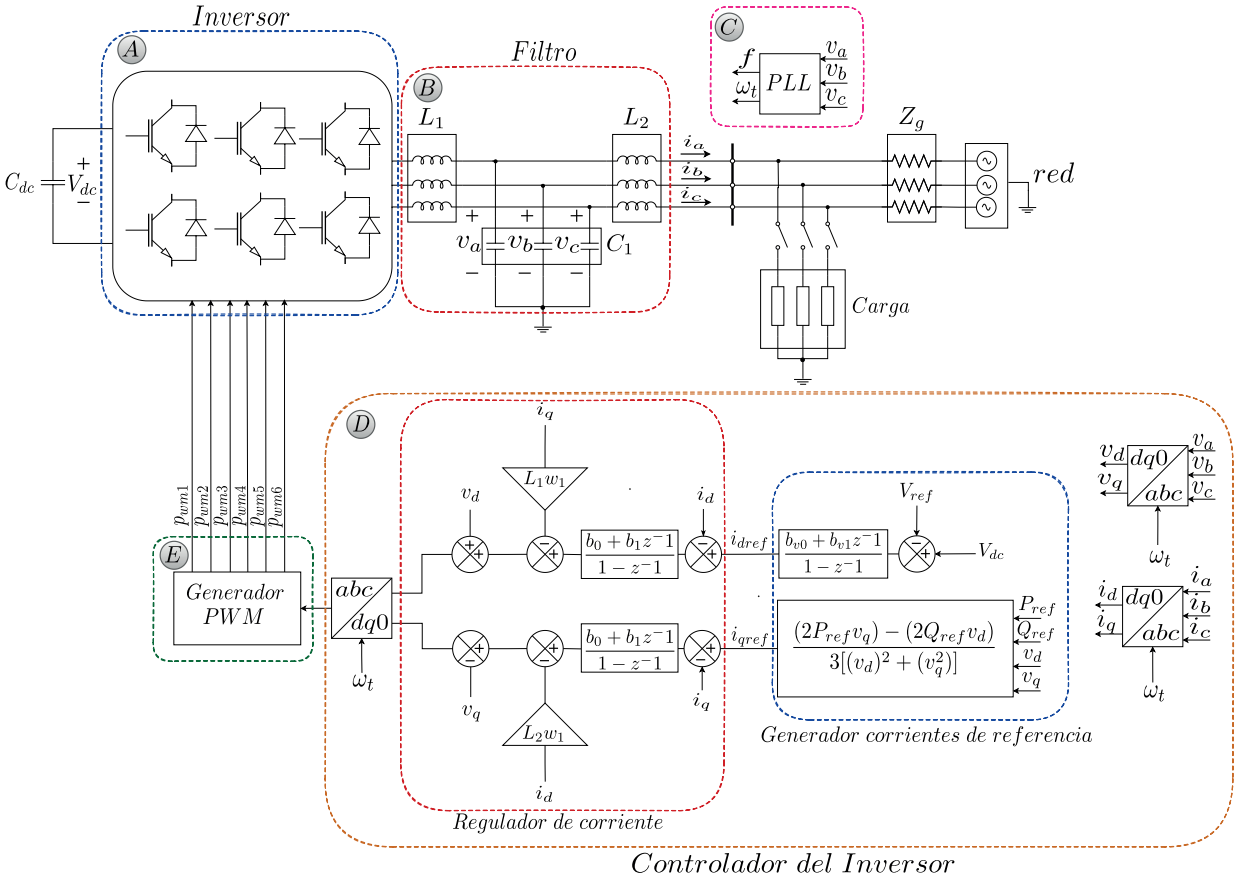

Figura 1.3: Diagrama del inversor

Tabla 1.2: Parámetros del inversor trifásico

Variable	Magnitud	Unidad de Medida
Potencia activa máxima del inversor trifásico (P_{max})	1937.28	W
Voltaje de la red (fase-neutro) (V_{grid})	120	V_{rms}
Voltaje DC de entrada(V_{dc})	420	V
Frecuencia de salida del inversor (f_0)	60	H_z
Frecuencia de conmutación de los semiconductores (f_{comp})	5000	H_z
Inductor 1 del filtro (L_1)	28	mH
Inductor 2 del filtro (L_2)	0.5	mH
Capacitor del filtro (C_1)	18	μF
Capacitor de entrada del inversor (C_{dc})	100	μF

1.4.1 Modelo del Inversor NPC trifásico de dos niveles

Un inverso trifásico puede ser caracterizado por medio de su modelo promediado, el cual considera que tanto los elementos del filtro LCL como del inversor son ideales; es decir, que la resistencia interna, la inductancia y la capacitancia son constantes, además se desprecian las perdidas en los núcleos de los inductores y el voltaje de la red se encuentra libre de armónicos, es simétrico y balanceado. De este modo, se sustituyen los dispositivos de conmutación, por fuentes dependientes, cuyo valor esta dado por el valor promedio de la señal en un ciclo de conmutación. La validez del modelo promediado está sujeta a que se cumpla la condición de que la frecuencia de la señal fundamental sea lenta con respecto a la frecuencia de conmutación. De igual forma, debe haber un bajo nivel de rizado en la señal fundamental, de manera que sea posible considerar el promedio constante durante el ciclo de conmutación [30].

Dado que la frecuencia de los dispositivos de conmutación es lo suficientemente alta, respecto de la fundamental, entonces es conveniente representar este sistema por su modelo promediado, como se muestra en la Figura 1.4.

Aplicando las leyes de voltaje y corriente de Kirchhoff al modelo, se obtiene

$$\begin{aligned}\frac{d_{iL1}}{dt} &= \frac{1}{L1}(e - v_C - R_c\, i_C)\\ \frac{d_{iL2}}{dt} &= \frac{1}{L2}(v_C + R_c\, i_C - v_g)\\ \frac{d_{vC}}{dt} &= \frac{1}{C_1}(i_{L1} - i_{L2}),\end{aligned} \tag{1.42}$$

donde L_1 representa al inductor del lado del inversor, L_2 es la inductancia del lado de la red, C_1 y R_c son el capacitor con su resistencia en serie, respectivamente, e es la entrada de control, mientras v_g es el voltaje fase a neutro en la red eléctrica.

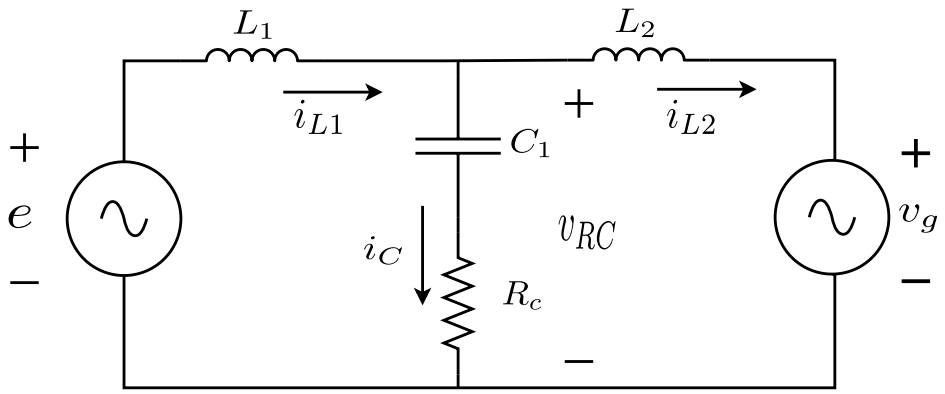

Figura 1.4: Modelo promediado inversor trifásico

El objetivo en el inversor es controlar la corriente de la bobina del lado de la red i_{L2} a través de la entrada e (tensión en las terminales del convertidor), siendo ésta última resultado de la actuación del controlador. Tomando i_{L2} y e respectivamente como entrada y salida, se puede encontrar una ecuación diferencial de grado tres que permita relacionarlas directamente. La función de transferencia que relaciona la entrada y la salida del filtro LCL es

$$G_{dp} = \frac{I_{L2}(s)}{E(s)} = \frac{sR_cC_1 + 1}{s(L_1L_2C_1s^2 + (L_1 + L_2)R_cC_1s + L_1 + L_2)}. \tag{1.43}$$

1.4.2 Cálculo filtro LCL

El filtro LCL tiene como principal objetivo, eliminar los armónicos de alta frecuencia generados por los semiconductores, y de esta forma inyectar a la red eléctrica una señal de corriente adecuada que posibilite mejorar la calidad de la potencia y la estabilidad del sistema. Por lo que el procedimiento de diseño parte del conocimiento de los parámetros de operación del sistema, como la potencia nominal (P_n), la frecuencia de conmutación del convertidor (f_{sw}), el voltaje fase neutro de la red (v_g) y la frecuencia fundamental de la red (f_0), como valores base, a partir de los cuales se calculan la impedancia base (Z_b), la inductancia base (L_b) y la capacitancia base (C_b), como se explica en [31], lo cual resulta en:

$$Z_b = \frac{v_g^2}{P_n}, \tag{1.44}$$

$$L_b = \frac{Z_b}{2\pi f_0}, \tag{1.45}$$

$$C_b = \frac{1}{2\pi f_0 Z_b}. \tag{1.46}$$

Ahora, se diseña el inductor (L_1) con el fin de reducir el rizado en la corriente generada por el inversor, con la expresión:

$$\begin{aligned} L_1 &= \frac{V_{dc}}{3\sqrt{3}\Delta I_{max} f_{sw}}, \\ \Delta I_{max} &= k_s \frac{P_n\sqrt{2}}{3v_g}, \end{aligned} \tag{1.47}$$

donde V_{dc} es el voltaje de entrada del inversor y k_s es una constante que indica el porcentaje de atenuación que frecuentemente se utiliza entre 0.1 y 0.2.

El valor del capacitor también tiene influencia en el rizado de la corriente, por lo que en [31] se recomienda establecer un factor menor o igual al 5 % cuando se requiere compensar la reactancia inductiva del filtro. Entonces, el capacitor C_1 puede ser encontrado con:

$$C_1 \leq 0.05 C_b. \tag{1.48}$$

Luego se calcula el inductor del lado de la red L_2, cuyo propósito es atenuar la distorsión armónica a los límites establecidos por los estándares de calidad. A continuación se detalla la expresión para calcular el valor de L_2:

$$L_2 = \frac{\frac{1-k_g}{k_g}}{W_{sw}^2 C_1 - \frac{1}{L_1}}, \tag{1.49}$$

donde (k_g) es el factor de atenuación que expresa la relación entre el rizado de la corriente inyectada a la red (i_{L2}) y el rizado de la corriente de salida del inversor (i_{L1}). Es importante resaltar que el valor máximo de inductancia combinada $(L_1 + L_2)$ debe estar limitado, por lo que se sugiere que el valor máximo de la inductancia combinada no exceda el 10 % del valor de inductancia base, es decir:

$$L_1 + L_2 \leq 0.1 L_b. \tag{1.50}$$

Una vez que los parámetros del filtro han sido seleccionados, es necesario verificar que la frecuencia de resonancia

$$f_{res} = \frac{1}{2\pi}\sqrt{\frac{L_1 + L_2}{L_1 L_2 C_1}}, \tag{1.51}$$

se encuentra dentro del rango

$$10 f_0 < f_{res} < 0.5 f_{sw}, \tag{1.52}$$

a fin de evitar problemas de resonancia e inestabilidad.

1.4.3 Seguimiento de fase y frecuencia PLL

El PLL es un control de lazo cerrado que rastrea la fase y la frecuencia de una señal trifásica. El controlador usado en este modelo está adaptado de la librería de Simulink [32] y tiene la composición ilustrada en la Figura 1.5.

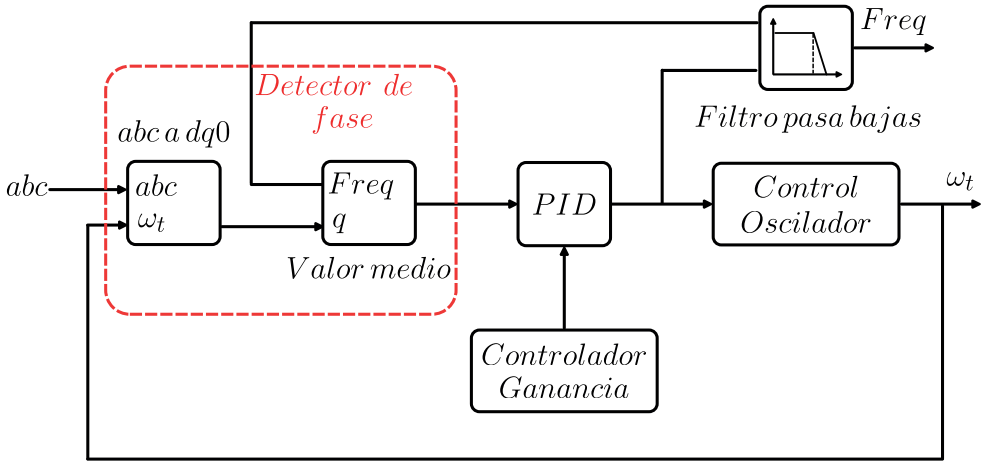

Figura 1.5: Estructura interna de un PLL

La señal de entrada trifásica se convierte en un marco giratorio $dq0$ (transformada de Park) utilizando la velocidad angular realimentada multiplicada por el tiempo wt.

Como el objetivo es hacer que el vector de tensión en $dq0$ coincida con el eje d para que la componente q se haga cero, se omite la primera componente.

A continuación, el eje de cuadratura de la señal, proporcional a la diferencia de fase entre la señal abc y el marco giratorio del oscilador interno, se filtra utilizando el valor promedio (frecuencia variable). Posteriormente, un controlador Proporcional-Integral-Derivativo (PID), con un control automático de ganancia (AGC), mantiene la diferencia de fase en 0 al actuar sobre un oscilador controlado. La salida del PID, correspondiente a la velocidad angular, se filtra y convierte a la frecuencia, en hercios (Hz), que utiliza el valor medio.

De los parámetros que deben introducirse al bloque PLL, se han dejado la mayoría en sus valores predeterminados, aunque sí se ha variado el periodo de muestreo y los valores del controlador PID, el cual para la presente investigación se cambió por un PI con el propósito de evitar la amplificación de ruido por el efecto derivativo del PID. Adicionalmente, los parámetros se sintonizaron buscando una respuesta en frecuencia sin sobrepaso y con un tiempo de establecimiento de aproximadamente 0.2 s, obteniendo $K_p = 15.43$ y $T_i = 0.0033$.

Dado que el inversor trifásico opera en tiempo discreto, resulta crucial determinar una relación entre las constantes continuas y discretas. Esta relación se tomó del libro *Sistemas de control en tiempo discreto* [33], de lo cual resulta:

$$K_{id} = \frac{K_p T}{T_i} \qquad K_{pd} = K_p - \frac{K_p T}{2T_i} \qquad k_{dd} = \frac{K_p\, T_d}{T}, \tag{1.53}$$

donde (T) es el periodo de muestreo, (K_p), (T_i) y (T_d) son las constantes continuas proporcional, integral y derivativa, (K_{pd}), (K_{id}) y (K_{dd}) son las constantes discretas proporcional, integral y derivativa, cuyos valores en este caso en particular son $K_{pd} = 15.2889$ y $K_{id} = 0.2777$.

1.4.4 Controlador de potencia activa y reactiva del inversor trifásico

En la literatura existen investigaciones que se han enfocado en la implementación de inversores trifásicos con capacidad de despacho de potencia reactiva. Sin embargo, en esta investigación se enfocó en el diseño de un controlador PI, un controlador PI resonante y un controlador por banda de histéresis.

1.4.4.1 Controlador PI: Este controlador comprende dos sistemas de control. El sistema interno se encarga de ajustar la corriente que fluye a través de los inductores (L_2) al controlar la activación y desactivación de los transistores IGBT. Por su parte, el sistema externo proporciona las referencias de corriente considerando tanto el voltaje DC de entrada como la potencia activa y reactiva que se desea inyectar a la red eléctrica.

En la Figura 1.3, se observa la necesidad de ajustar dos controladores PI, dado que el lazo de corriente del inversor se regula mediante dos PI idénticos. En consecuencia, se procede a sintonizar inicialmente los valores del controlador PI encargado de regular la corriente del inversor. Un controlador PI convencional se encuentra definido mediante la función de transferencia

$$G_{pi} = K_p + \frac{K_i}{s}, \tag{1.54}$$

donde (K_p) y (K_i) son las ganancias proporcional e integral, respectivamente. Ahora, si tenemos en cuenta la función de transferencia del sistema (1.43), es posible hallar la función de transferencia en lazo cerrado mediante la siguiente expresión:

$$\begin{aligned}
G_{ba} =& G_{dp}G_{pi} = \frac{(K_p s + K_i)(sR_cC_1 + 1)}{s^2(L_1L_2C_1s^2 + (L_1 + L_2)R_cC_1s + L_1 + L_2)} \\
G_{lc} =& \frac{1 + G_{ba}}{G_{ba}} \\
G_{lc} =& \frac{C_0s^2 + C_1s + C_2}{D_0s^4 + D_1s^3 + D_2s^2 + D_3s + D_4} \\
C_0 =& R_cC_1K_p \\
C_1 =& K_p + K_iR_cC_1 \\
C_2 =& K_i \\
D_0 =& L_1L_2C_1 \\
D_1 =& (L_1 + L_2)C_1R_c \\
D_2 =& L_1 + L_2 + K_pC_1R_c \\
D_3 =& K_p + K_iC_1R_c \\
D_4 =& K_i.
\end{aligned} \tag{1.55}$$

Con el sistema en lazo cerrado se obtiene el polinomio característico y se sintonizan los parámetros del PI con los cuales el sistema sea estable y presente un bajo sobrepaso, obteniendo una $K_p = 2$ y una $K_i = 40$.

Posteriormente, se calculan las contantes discretas del controlador PI utilizando la ecuación (1.53), encontrando que $K_{pd} = 1.9988$ y $K_{id} = 0.0024$. Finalmente, se encuentran los parámetros del filtro digital mostrado a continuación:

$$\begin{aligned} G_{pic}(z) =& (\frac{b_0 + b_1 z^-1}{1 - z^-1}) \\ b_0 =& K_{pd} + K_{id} = 2.0012 \\ b_1 =& - K_{pd} = -1.9988. \end{aligned} \tag{1.56}$$

Una vez se tienen calibrados los controladores del lazo interno de corriente, se procede a sintonizar el PI que regula el voltaje de entrada del bus DC. Por lo tanto, se sigue la metodología anterior y se obtiene la función de transferencia

$$\begin{aligned} G_{bav} =& G_{ba} G_{piv} = G_{ba}(K_{pv} + \frac{K_{iv}}{s}) \\ G_{vlc} =& \frac{1 + G_{bav}}{G_{bav}} \end{aligned} \tag{1.57}$$

Al igual que en el caso anterior, se obtiene el polinomio característico y se calibran los parámetros del PI para que el sistema sea estable y presente un bajo sobrepaso, obteniendo una $K_p = 0.025$ y una $K_i = 0.001$. Por su parte, los parámetros del filtro digital son:

$$\begin{aligned} G_{piv}(z) =& (\frac{b_{v0} + b_{v1} z^-1}{1 - z^-1}) \\ b_{v0} =& 0.25 \\ b_{v1} =& - 0.25. \end{aligned} \tag{1.58}$$

1.4.4.2 Controlador PI resonante: Este controlador comprende dos sistemas de control. El sistema interno ajusta la corriente que pasa por los inductores (L_2) al controlar la activación y desactivación de los transistores IGBT. Mientras tanto, el lazo externo proporciona las referencias de corriente considerando la potencia activa y reactiva que se pretende inyectar a la red eléctrica. (Figura 1.6).

Un controlador PI resonante se encuentra definido por la función de transferencia

$$G_{pir} = K_{pr} + \frac{K_{ir}\omega_c s}{s^2 + 2\omega_c s + \omega_0^2}, \tag{1.59}$$

donde (ω_c) es una constante de amortiguamiento, (ω_0) es la velocidad angular de la red $(2\pi 60)$ y (K_{pr}) y (K_{ir}) son las ganancias proporcional e integral, respectivamente. Aplicando la misma metodología que en el caso anterior, se procede a encontrar la función de transferencia del sistema en lazo cerrado.

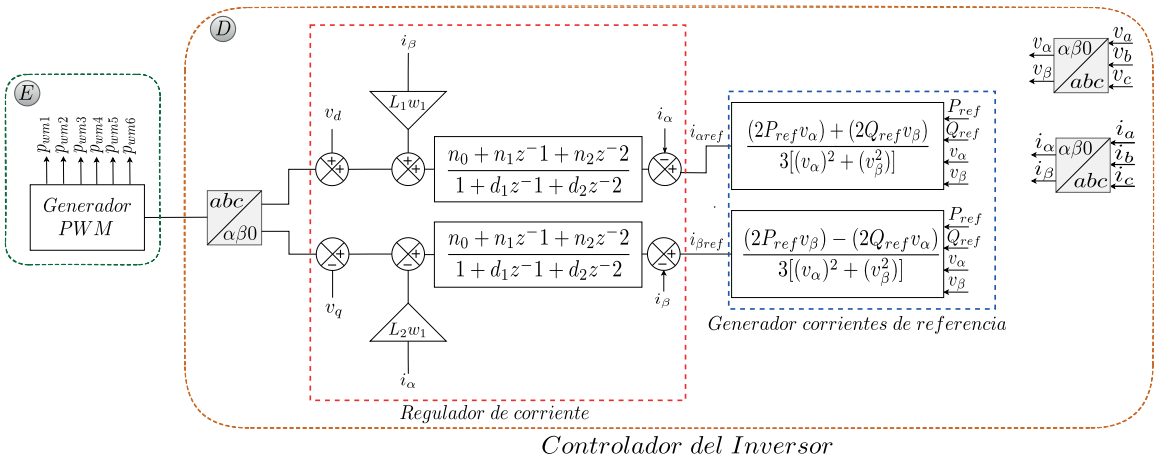

Figura 1.6: Esquema de control del inversor con el regulador PI resonante

$$
\begin{aligned}
G_{bar} =& G_{dp}G_{pir} = (K_{pr} + \frac{K_{ir}\omega_c s}{s^2+2\omega_c s+\omega_0^2})... \\
& (\frac{sR_cC_1+1}{s(L_1L_2C_1s^2+(L_1+L_2)R_cC_1s+L_1+L_2)}) \\
G_{lcr} =& \frac{1+G_{bar}}{G_{bar}} \\
G_{lcr} =& \frac{A_0s^3+A_1s^2+A_2s+A_3}{B_0s^5+B_1s^4+B_2s^3+B_3s^2+B_4s+B_5} \\
A_0 =& R_cC_1K_{pr} \\
A_1 =& K_{pr}+(2K_{pr}+K_{ir})\omega_cR_cC_1 \\
A_2 =& (2K_{pr}+K_{ir})\omega_c + K_{pr}R_cC_1\omega_0^2 \\
A_3 =& K_{pr}\omega_0^2 \\
B_0 =& L_1L_2C_1 \\
B_1 =& (L_1+L_2)C_1R_c + 2L_1L_2C_1\omega_c \\
B_2 =& (L_1+L_2)(1+2\omega_cC_1R_c) + L_1L_2C_1\omega_0^2 + K_{pr}C_1R_c \\
B_3 =& (L_1+L_2)(2\omega_c + C_1R_c\omega_0^2) + K_{pr} + ... \\
& (K_{ir}+2K_{pr})C_1R_c\omega_c \\
B_4 =& (L_1+L_2)\omega_0^2 + K_{pr}C_1R_c\omega_0^2 + (K_{ir}+2K_{pr})\omega_c \\
B_5 =& K_{pr}\omega_0^2.
\end{aligned}
\tag{1.60}
$$

De igual forma que en el controlador PI, se obtiene el polinomio característico y se calibran los parámetros del PI resonante para que el sistema sea estable y presente un bajo sobrepaso, obteniendo una $K_{pr} = 10$ y una $k_{ir} = 15000$.

En seguida se sintonizan los parámetros del filtro digital teniendo en cuenta que se realiza una aproximación del controlador por medio de la transformación bilineal ($s = \frac{2}{T}\frac{1-z^{-1}}{1+z^{-1}}$), de la cual resulta:

$$\begin{aligned}
G_{pir}(z) =& (\frac{n_0 + n_1 z^-1 + n_2 z^-2}{1 + d_1 z^-1 + d_2 z^-2}) \\
n_0 =& \frac{(4 + 4T\omega_c + \omega_0^2 T^2)K_{pr} + 4K_{ir}T\omega_c}{4 + 4T\omega_c + \omega_0^2 T^2} \\
n_1 =& \frac{(-8 + 2\omega_0^2 T^2)K_{pr}}{4 + 4T\omega_c + \omega_0^2 T^2} \\
n_2 =& \frac{(4 - 4T\omega_c + \omega_0^2 T^2)K_{pr} - 4K_{ir}T\omega_c}{4 + 4T\omega_c + \omega_0^2 T^2} \\
d_1 =& \frac{(-8 + 2\omega_0^2 T^2)}{4 + 4T\omega_c + \omega_0^2 T^2} \\
d_2 =& \frac{4 - 4T\omega_c + \omega_0^2 T^2}{4 + 4T\omega_c + \omega_0^2 T^2}.
\end{aligned} \tag{1.61}$$

1.4.4.3 Controlador sinusoidal por banda de histéresis: El control por banda de histéresis es ampliamente empleado en el ámbito del filtrado activo de corriente. Su característica principal reside en que la generación de la señal de referencia y su modulación se llevan a cabo de manera simultánea, por lo que, el método tiene la capacidad de proporcionar la respuesta dinámica más rápida posible. Este controlador tiene la particularidad que la banda de histéresis varía sinusoidalmente sobre un periodo de la fundamental [34]. El modelo matemático del controlador está dado por:

$$\begin{aligned}
i_{ref} =& i_m sen(\omega t) \\
i_{up} =& (i_m + HB) sen(\omega t) \\
i_{low} =& (i_m - HB) sen(\omega t),
\end{aligned} \tag{1.62}$$

donde i_{ref} es la corriente de compensación, i_{up} es la banda superior o límite superior, i_{low} es la banda inferior o límite inferior, i_m es la amplitud de la señal corriente y HB es la banda de corriente de ancho fijo (banda de histéresis).

No obstante, este controlador presenta la desventaja de requerir una señal sinusoidal de referencia, lo que puede generar inestabilidad en el sistema al momento que se presenten cambios bruscos en la irradiancia o en la demanda. Para solventar esta problemática y mejorar el rendimiento del controlador, en esta investigación se empleó un controlador PI resonante que permite estabilizar la señal de corriente en el inversor, funcionando como señal de referencia para el controlador por banda de histéresis siguiendo el esquema de control que se ilustra en la Figura 1.7. Cabe destacar que el controlador PI resonante empleado es el mismo que se sintonizó en el apartado anterior.

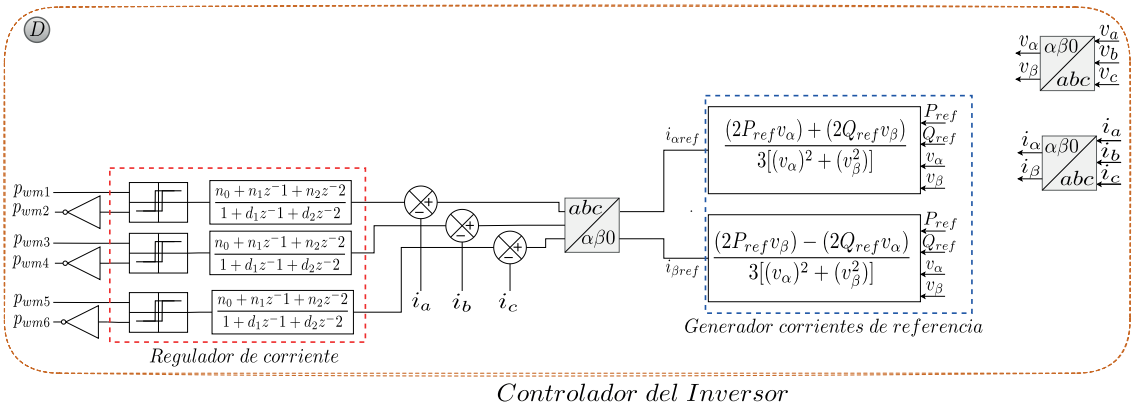

Figura 1.7: Esquema de control mediante banda de histéresis

1.4.5 Generador de pulsos PWM

Este generador de pulsos se encuentra en la librería de Simulink [35] y se usa para controlar los dispositivos de conmutación (FET, GTO o IGBT) en el convertidor trifásico. La señal de referencia, también llamada señal de modulación, se compara con una portadora triangular simétrica de 5 kH_z. Cuando la señal de referencia es mayor que la portadora, el pulso para el dispositivo de conmutación superior es alto (1) y el pulso para el dispositivo inferior es bajo (0).

1.5 Implementación experimental

OPAL-RT es una empresa que se dedica al desarrollo de equipos basados en PC y FPGA, así como equipos de pruebas SIL (*Software in the Loop*) y HIL (*Hardware in the Loop*). Algunas de las aplicaciones principales para estos sistemas son la simulación de redes eléctricas y de equipos basados en electrónica de potencia [36]. En este trabajo se usa el equipo de simulación en tiempo real OP4510, con el fin de analizar el comportamiento del inversor trifásico ante condiciones ambientales desafiantes como variaciones en la irradiancia desde la generación y cambios en la demanda desde las cargas en un esquema de control en el entorno SIL. Para información detallada sobre el funcionamiento y la configuración de la plataforma, se recomienda revisar la guía de usuario [37].

La simulación en la plataforma de tiempo real se realiza por medio del entorno RT-LAB. Este entorno es el encargado de la compilación, carga y simulación de los modelos en el equipo OP4510. La versión de RT-LAB usada es la v2022.1.0.405, compatible con la versión de Matlab 2021b. Una vez se tiene instalada la versión de Matlab, es necesario instalar dos extensiones en Matlab: RT-LAB y RTEVENTS.

Luego de instalados los programas y paquetes necesarios para la simulación, se procede a cargar el modelo en OPAL-RT. El modelo debe ser dividido en dos subsistemas interco-

nectados: un primer subsistema, cuyo nombre debe empezar con SM, y otro cuyo nombre empiece por SC, tal como se muestra en la Figura 1.8.

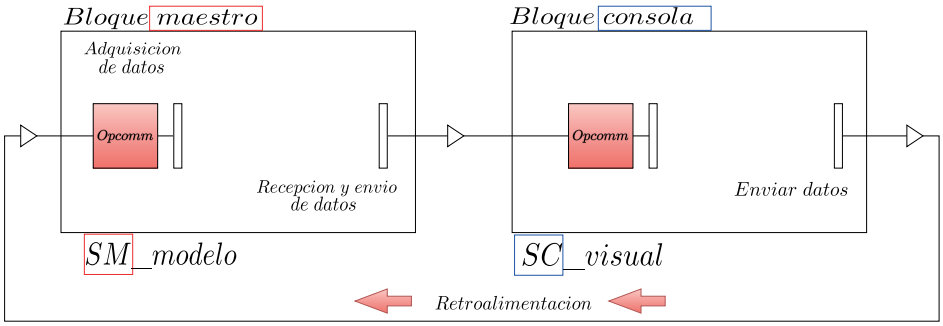

Figura 1.8: Estructura Maestro- Consola del archivo en simulink en el entorno RT-LAB

Como se puede apreciar, en el subsistema SM (*System Master*), se incluyen todos los bloques que intervengan en el cálculo dentro del modelo. Por otra parte, en el subsistema SC (*System Console*) deben incorporarse todos los bloques que actúen como interfaz hombre-máquina, incluyendo las variables cuyo valor se modifique a lo largo de la simulación y aquellas cuyo valor se quiera monitorizar en tiempo real.

Además de dividir el modelo, es necesario introducir una serie de bloques para el correcto funcionamiento de la simulación en tiempo real. Por fuera de los bloques SM y SC se debe incluir los bloques *powergui*, encargado de facilitar la simulación de los bloques de las biblioteca *Simscape, Electrical and Specialized Power Systems* y *Model Initialization*, por medio del cual se inicializan los parámetros del sistema. Otro de los bloques que deben incorporarse en el modelo es el denominado *OpComm*. Este bloque se encarga de gestionar la comunicación entre los distintos subsistemas. Por lo tanto, es imprescindible incluir uno en SM y otro en SC.

Posteriormente, es necesario incluir los archivos que posibiliten la incorporación de las funciones de tiempo *tic y toc* y las $S-function$ con variables permanentes en el entorno RT-LAB, o de lo contrario saltará un error que interrumpe la compilación. Esto se hizo desde el campo $Files$, donde se incluyen los ficheros denominados $DSS_Utils.c$, $Sfun_discreteVariableDelay.c$, $Sfun_spssw_discc_DSS.c$ y $Coder_posix_time.c$.

En este punto, la simulación debería compilarse en la plataforma sin ninguna dificultad; sin embargo, es posible se presenten inconvenientes con el modelo de panel solar de la biblioteca *Electrical and Specialized Power Systems* de Simulink, el cual no está optimizado para el funcionamiento en el equipo de simulación en tiempo real. Por ello, se empleó un nuevo modelo de panel solar que estuviera optimizado para el entorno RT-LAB. No obstante, este nuevo modelo presentaba diversas falencias al momento de ser incorporado al convertidor DC/DC. Entre las más representativas se encontraban: i) la no convergencia del método numérico durante la simulación y ii) la presencia de oscilaciones significativas al momento de emplear el modelo en PSC. Por lo anterior, se realizaron diversas modificacio-

nes al nuevo modelo de panel solar con el fin de solucionar las mencionadas problemáticas. Entre las variaciones más significativas se encuentran: i) la incorporación de memorias que resuelvan las problemáticas de convergencia del método numérico, ii) la alteración de los parámetros empleados en la máscara del sistema y iii) la incorporación de filtros pasivos LC que reduzcan significativamente las oscilaciones en las salidas de corriente y tensión del módulo fotovoltaico. Se resalta que el modelo definitivo de panel solar usa los mismos parámetros de configuración que el modelo de la librería *Specialized Power Systems*.

1.6 Resultados y discusión

Para validar los controladores implementados, se somete el sistema propuesto (Figura 1.1) a variaciones de irradiancia desde la generación y cambios bruscos en las cargas desde la demanda. Por lo anterior y debido a la gran cantidad de controladores empleados el sistema se analizó desde tres escenarios.

En el primero se evalúa el desempeño de los 7 algoritmos GMPPT híbridos implementados en la etapa de conversión DC/DC empleando solamente el sotfware Simulink. Luego del análisis en la etapa de conversión DC/DC y una vez definido el mejor algoritmo GMPPT híbrido, se procede a examinar el comportamiento del inversor solar trifásico empleando los controladores PI, PI resonante y por banda de histéresis. Se resalta que este estudio se realizó en Simulink empleando el controlador MPPT híbrido con el mejor desempeño. Finalmente, se elabora un comparativo de los resultados obtenidos en simulación y en la plataforma de tiempo real OPAL-RT.

1.6.1 Análisis de los controladores empleados en la etapa del convertidor DC/DC

Para verificar el correcto funcionamiento de los reguladores MPPT híbridos, el sistema propuesto en la Figura 1.1 se somete a condiciones ambientales desafiantes como: i) condiciones de PSC convencionales que contengan el mayor número de puntos locales de máxima potencia (LMPP) y ii) varias PSC que cambian rápidamente en un mismo intervalo de tiempo.

1.6.1.1 Condiciones de PSC convencional: En esta sección se explica el diseño de las condiciones PSC convencionales, que consiste en someter al sistema a una única condición de sombreado parcial que presenta múltiples picos LMPP.

Escenario 1: En este escenario, los 6 módulos $(Irr_1 - Irr_6)$ presentados en la Figura 1.1 reciben una irradiancia solar de $[1000, 1000, 200, 1000, 1000, 200]\ \frac{W}{m^2}$. Bajo esta condición, el GMPP se encuentra en 1277.03 W. Las características $P - V$ de salida del sistema fotovoltaico en estas condiciones de PSC, el rendimiento de salida de los algoritmos MPPT híbridos y sus tiempos de establecimiento se muestran en la Figura 1.9.

Los resultados muestran que los algoritmos ABC, RMO y ARMO no fueron capaces de encontrar el punto GMPP. De igual forma, estos algoritmos presentaron los tiempos de establecimientos más altos, siendo el algoritmo ARMO el que obtuvo el peor rendimiento

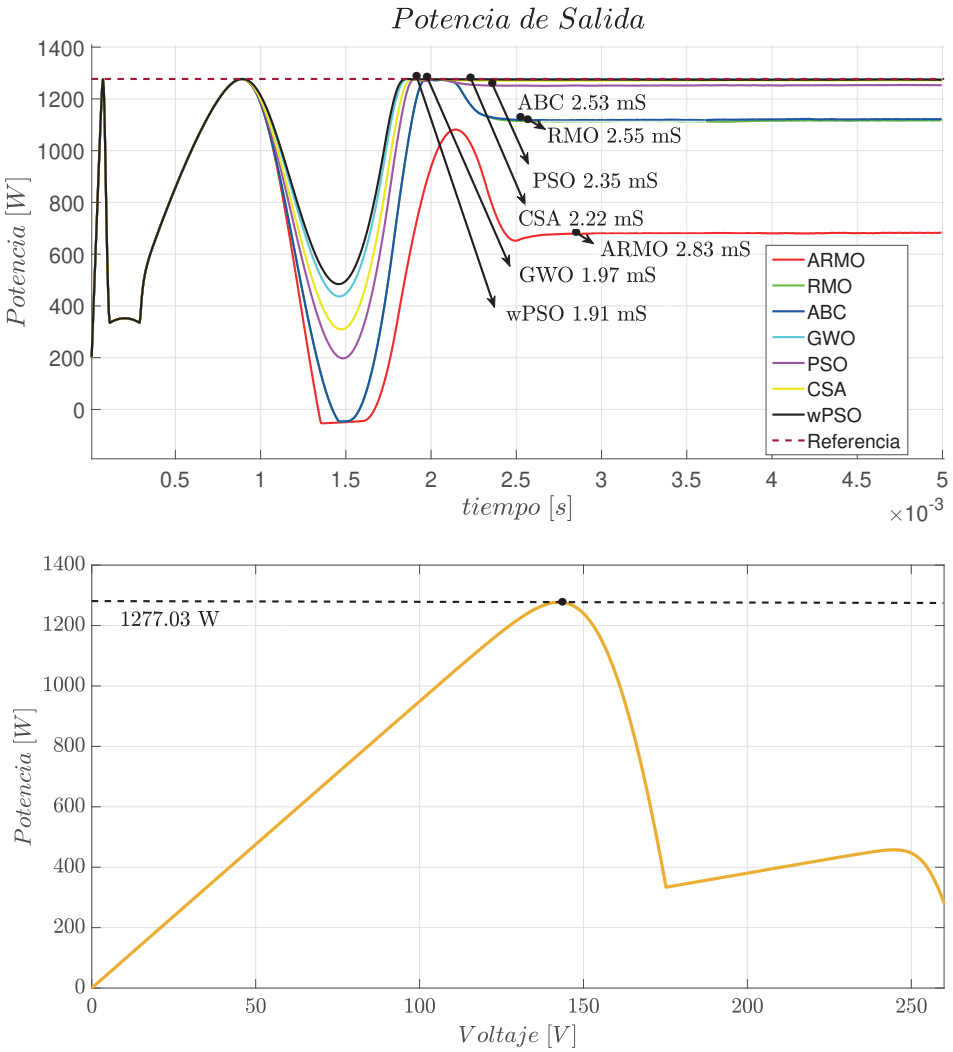

Figura 1.9: Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 1

de todos para este perfil de irradiancia. Adicionalmente, se evidencia que el algoritmo PSO, a pesar de obtener mejores resultados que los algoritmos ABC, RMO y ARMO, consiguió una respuesta regular en el seguimiento del GMPP y un mayor tiempo de establecimiento si se lo compara con los algoritmos GWO, wPSO y CSA. Asimismo, en la Figura 1.9 se detalla que el algoritmo wPSO obtuvo el menor tiempo de establecimiento y se aproximó bastante al GMPP. De forma muy similar, los métodos GWO y CSA obtuvieron un muy buen acercamiento al punto GMPP. Por otra parte, es importante destacar que ninguno de los algoritmos híbridos convergió al punto LMPP y los métodos ARMO, RMO y ABC se estacionaron en potencias que se encuentran entre el GMPP y LMPP. Este fenómeno

se debe a que la búsqueda de los algoritmos se detuvo al alcanzar el número máximo de iteraciones posibles.

Escenario 2: En el segundo escenario, los 6 módulos $(Irr_1 - Irr_6)$ presentados en la Figura 1.1 reciben una irradiancia solar de $[1000, 800, 200, 1000, 800, 200]\ \frac{w}{m^2}$. Bajo esta condición, el GMPP se encuentra en 1085.98 W. Las características $P - V$ de salida del sistema fotovoltaico en estas condiciones de PSC, el rendimiento de salida de los algoritmos MPPT híbridos y sus tiempos de establecimientos se muestran en la Figura 1.10.

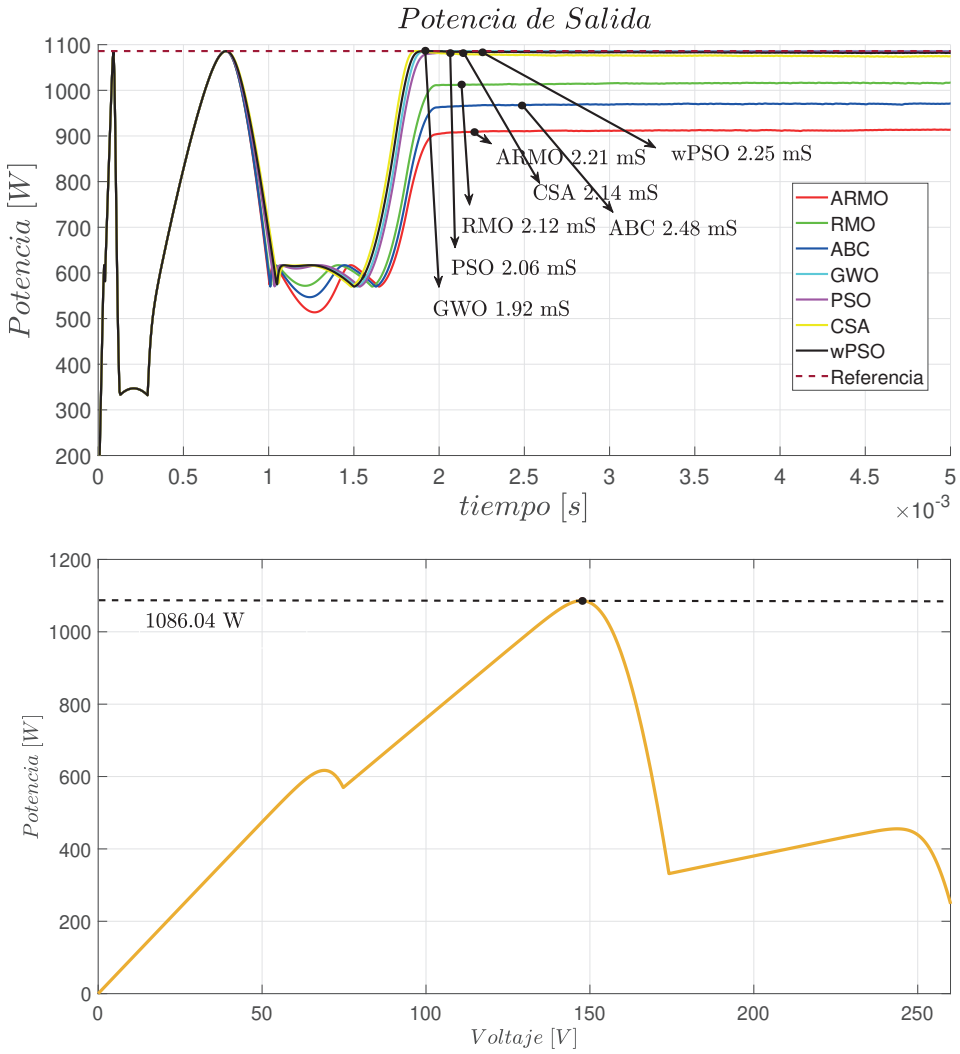

Figura 1.10: Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 2

En este perfil de irradiancia es posible observar que los métodos ABC, RMO y ARMO obtuvieron un mal desempeño con respecto al seguimiento del punto GMPP. De igual forma,

se observa que el algoritmo PSO presentó un mejor seguimiento del GMPP, llegando a superar al método CSA. Por su parte, los métodos GWO y wPSO obtuvieron una excelente convergencia al GMPP. Sin embargo, es importante mencionar que el tiempo de establecimiento del wPSO presentó un aumento considerable, siendo el segundo peor después del algoritmo ABC. Además, los algoritmos RMO y ARMO obtuvieron mejores tiempos de establecimientos comparados con el primer perfil de irradiancia, siendo el tercero y cuarto respectivamente. Finalmente, es relevante destacar que el método GWO presentó el menor tiempo de establecimiento y un muy buen acercamiento al GMPP en este escenario.

Escenario 3: En el tercer escenario, los 6 módulos $(Irr_1 - Irr_6)$ presentados en la Figura 1.1 reciben una irradiancia solar de $[1000, 600, 600, 1000, 400, 800]\ \frac{w}{m^2}$. Bajo esta condición, el GMPP se encuentra en 1067.57 W. Las características $P - V$ de salida del sistema fotovoltaico en estas condiciones de PSC y el rendimiento de salida de los algoritmos MPPT híbridos se muestran en la Figura 1.11.

En la Figura 1.11 se observa que los algoritmos ABC, RMO y ARMO siguen presentando el peor desempeño en la convergencia al punto GMPP. Mientras que los métodos GWO, wPSO, PSO y CSA presentan una excelente convergencia al punto GMPP. Ahora, si se evalúa el tiempo de establecimiento, la Figura 1.11 demuestra que el peor desempeño lo obtuvo el método RMO, seguido de los algoritmos CSA, wPSO, PSO, ARMO y GWO, respectivamente, los cuales obtuvieron un desempeño bastante similar entre ellos.
Por último, el algoritmo ABC consiguió el menor tiempo de establecimiento contrario a lo sucedido en los perfiles anteriores en los que estuvo ubicado en los métodos con el peor desempeño.

Escenario 4: En este escenario, los 6 módulos $(Irr_1 - Irr_6)$ presentados en la Figura 1.1 reciben una irradiancia solar de $[1000, 200, 400, 800, 400, 600]\ \frac{W}{m^2}$. Bajo esta condición, el GMPP se encuentra en 724.54 W. Las características $P - V$ de salida del sistema fotovoltaico en estas condiciones de PSC y el rendimiento de salida de los algoritmos MPPT híbridos se muestran en la Figura 1.12.

En este perfil de irradiancia es posible observar que los algoritmos ABC, CSA y ARMO presentan un mal desempeño en la convergencia al GMPP, puesto que se quedaron atrapados en un LMPP. De igual manera, los métodos GWO y RMO se estancaron en un LMPP, mientras los algoritmos wPSO y PSO sí fueron capaces de llegar al GMPP, obteniendo el mejor desempeño en este escenario. Ahora, con respecto al tiempo de establecimiento, se observa que el wPSO y PSO obtuvieron el peor desempeño, seguidos de los algoritmos RMO,GWO, ARMO, ABC y CSA, respectivamente. Finalmente, el algoritmo CSA presentó el menor tiempo de establecimiento en este escenario, lo que permite evidenciar que en condiciones de PSC con bastantes LMPP, los métodos que convergen al GMPP tienden a demorarse más tiempo en establecerse que los métodos que quedan atrapados en LMPP.

1.6.1.2 PSC que varían rápidamente en un mismo intervalo de tiempo: Las sombras en movimiento son condiciones ambientales comunes que cambian rápidamente, y causan alteraciones significativas en la estabilidad y eficiencia de un sistema fotovoltaico [14]. Es

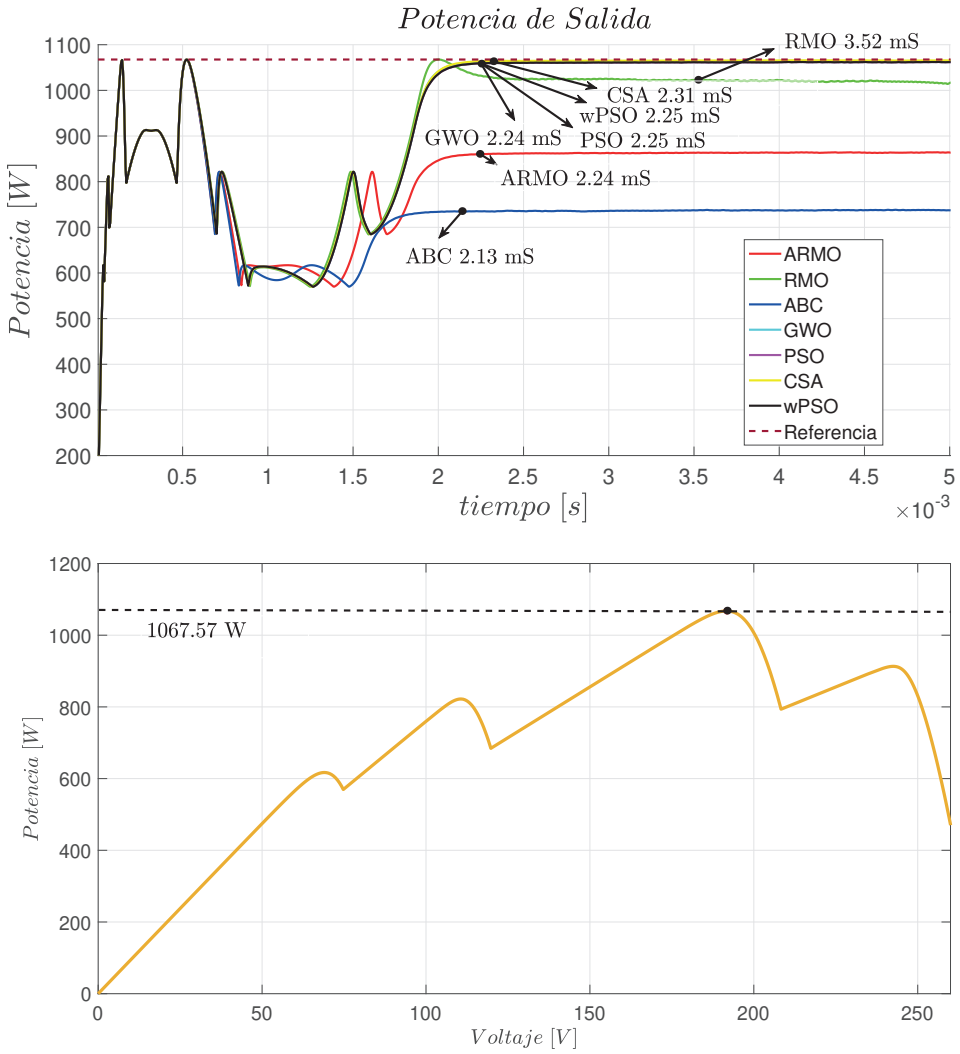

Figura 1.11: Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 3

por ello que el algoritmo MPPT híbrido debe ser rápido y fiable al momento de enfrentarse a este tipo de condiciones que puede afectar el rendimiento general del sistema.

Por lo anterior, resulta relevante analizar el comportamiento de los algoritmos MPPT híbridos en este tipo de condiciones ambientales. Por lo que, en este escenario, los 6 módulos $(Irr_1 - Irr_6)$ presentados en la Figura 1.1 son sometidos a cinco condiciones de PSC que cambian cada 0.5 segundos y cuyos perfiles de irradiancia se encuentran resumidos en la Tabla 1.3.

Los resultados en la ejecución de cada algoritmo en el escenario propuesto (Figura 1.1) se resumen en la Figura 1.13.

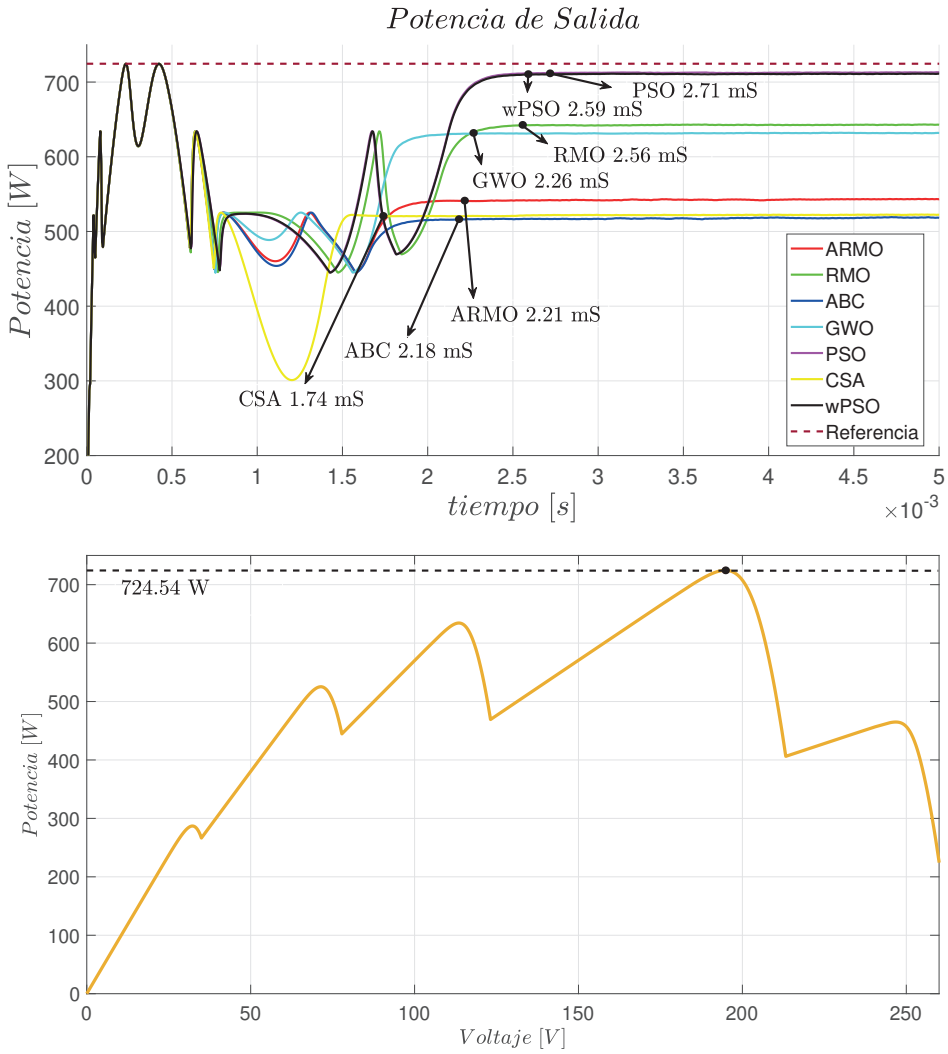

Figura 1.12: Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 4

Los resultados expuestos son bastantes similares a los obtenidos al momento de analizar los perfiles de irradiancia uno por uno, donde los algoritmos ARMO, RMO y ABC siguen presentando el peor desempeño con respecto a la búsqueda del GMPP, y el método wPSO fue el único que logro alcanzar el GMPP en todos los perfiles de irradiancia. No obstante, en este escenario se observa que al combinar las PSC el algoritmo PSO ya no consigue converger al GMPP en el perfil de irradiancia 4, obteniendo el peor desempeño en ese caso, lo que expone las debilidades en la búsqueda del GMPP que tiene el método.

Otro fenómeno que se presenta en las condiciones variables de PSC es que los algoritmos RMO, ARMO y ABC no consiguieron encontrar el GMPP en el perfil de irradiancia 3, en el que hay solo un punto de máxima potencia. Esto se debe a que los algoritmos alcanzaron

Tabla 1.3: Escenario de prueba en PSC variables

Perfil $\left(\frac{kW}{m}\right)$	**GMPP** (V, I)	**GMPP** (W)
$[1\ \ 1\ \ 0.2\ \ 1\ \ 1\ \ 0.2]$	$[142.54\ \ 8.96]$	1277.03
$[1\ \ 0.8\ \ 0.2\ \ 1\ \ 0.8\ \ 0.2]$	$[147.64\ \ 7.36]$	1085.98
$[1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 1]$	$[215.42\ \ 8.99]$	1937.28
$[1\ \ 0.6\ \ 0.6\ \ 1\ \ 0.4\ \ 0.8]$	$[191.79\ \ 5.57]$	1067.57
$[1\ \ 0.2\ \ 0.4\ \ 0.8\ \ 0.4\ \ 0.6]$	$[194.86\ \ 3.72]$	724.54

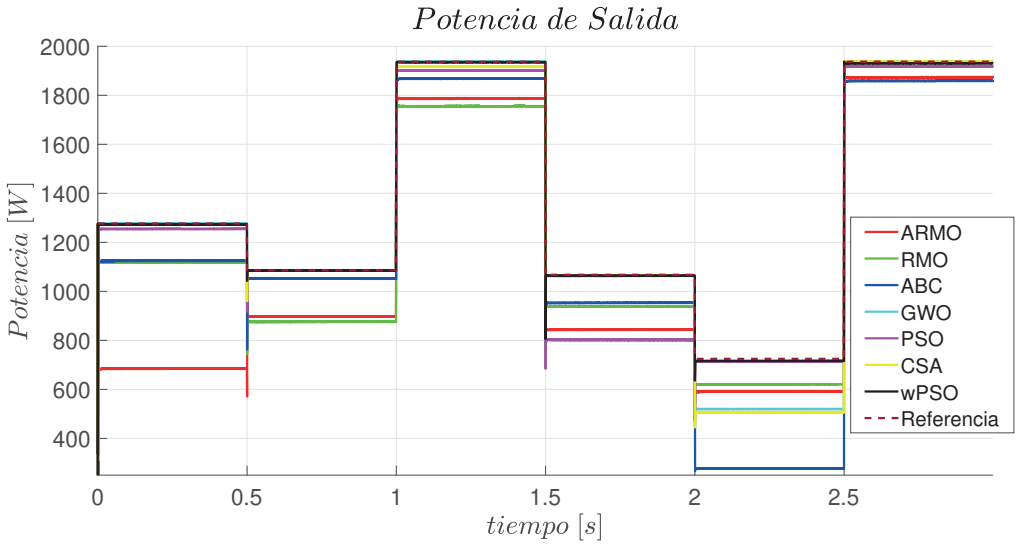

Figura 1.13: Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos donde se varía las PSC

el máximo número de iteraciones posibles antes de encontrar el GMPP. Para solucionar esta problemática se puede aumentar el número de iteraciones, aunque esta acción debe realizarse con cuidado, ya que si se aumenta considerablemente las iteraciones, pueden presentarse problemas de inestabilidad en el sistema por el incumplimiento del periodo de muestreo establecido.

Pese a lo anterior y en vista de que solamente se ha examinado el comportamiento de los algoritmos en su capacidad de convergencia al punto GMPP, en la presente investigación se profundizó en el análisis de los métodos MPPT híbridos teniendo en cuenta las siguientes métricas: i) el Error Absoluto Medio (MAE - *Mediam Absolute Error*), ii) la integral del error al cuadrado (ISE- *Integral Square-Error*), iii) la integral del error al cuadrado multiplicado por el tiempo (ITSE-*Integral of Time Multiplied Equared Error*), iv) el error

cuadrático medio (MSE- *Mean Squared Error*), v) el tiempo de ejecución de cada algoritmo, vi) la correlación entre la señal de potencia obtenida con cada algoritmo y la señal de potencia en el punto GMPP y vii) el factor de seguimiento del punto GMPP, el cual se calcula promediando el valor de potencia obtenido por cada algoritmo MPPT híbrido en los 5 perfiles de irradiancia.

En ese sentido, los resultados obtenidos por cada uno de los ítems se resumen en la Figura 1.14 y en la Tabla 1.4. Cabe puntualizar que para los primeros 5 aspectos se normalizaron los resultados en el intervalo $[0, 1]$.

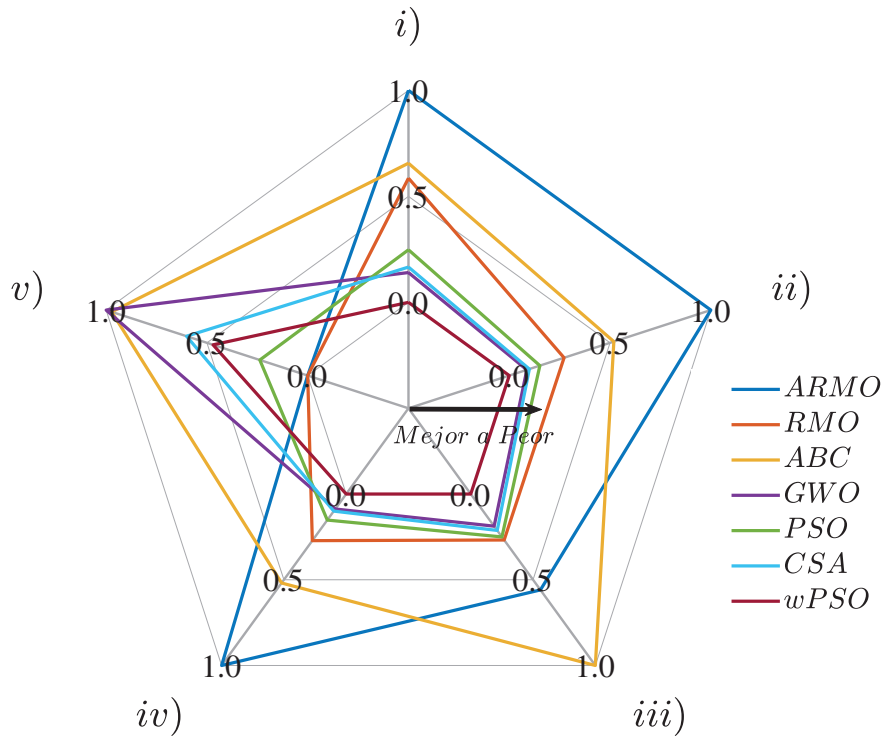

Figura 1.14: Comparación de las técnicas híbridas MPPT según los 5 primeros aspectos

Teniendo en cuenta la Figura 1.14 y la Tabla 1.4, el método wPSO presenta el mejor desempeño de todos los algoritmos evaluados al ganar en 6 de los 7 aspectos tenidos en cuenta para este estudio. Por otra parte, el algoritmo GWO obtuvo el segundo mejor desempeño en los escenarios analizados, pues logró obtener la segunda mejor respuesta en 6 de los 7 aspectos evaluados. Seguidamente y muy cerca del desempeño del GWO, se encuentra el método CSA, el cual obtuvo el tercer mejor desempeño en 4 de los 7 aspectos examinados. Finalmente, los algoritmos PSO, RMO, ABC y ARMO adquirieron la cuarta, quinta, sexta y séptima posición, respectivamente.

Tabla 1.4: Similitud y Factor de seguimiento del punto GMPP

Algoritmo	Correlación los puntos GMPP (%)	Factor de seguimiento del GMPP (%)
ARMO	94.5810	77.7949
RMO	99.1402	86.4892
ABC	97.9947	81.7760
GWO	99.2485	94.2288
PSO	98.1235	93.9880
CSA	99.1141	93.6421
wPSO	**99.9500**	**99.5874**

1.6.2 Análisis comparativo de los resultados obtenidos en el inversor en la simulación basada en modelos matemáticos y en la plataforma de simulación de tiempo real OPAL-RT

Para evaluar el desempeño de los tres controladores realizados en el inversor fotovoltaico trifásico, se examina el sistema considerando principalmente tres aspectos: i) el desempeño y la eficiencia de los controladores implementados al momento de presentar PSC variables, cambios bruscos en la demanda e inyección de potencia reactiva por parte del inversor, ii) la capacidad máxima de despacho de potencia reactiva del inversor y iii) el correcto balance de potencias activas y reactivas bajo cambios bruscos en la demanda y condiciones de PSC variable.

1.6.2.1 Inversor trifásico bajo PSC variables en Simulink: En este escenario se varían rápidamente PSC en los mismos perfiles de irradiancia de la sección anterior (Tabla 1.3), que cambian cada segundo. Cabe resaltar, que el inversor entra en funcionamiento después de 0.2 s mientras se estabilizan las señales de referencia de corriente y se mide la frecuencia de la red eléctrica por medio del regulador PLL. Adicionalmente, el inversor en cada cambio de perfil de irradiancia (cada segundo) inyecta una potencia reactiva de $[-1500, -1000, 0, 1000, 0]$ *VAr*, respectivamente. Asimismo, la carga trifásica cada segundo requiere $[0, 950, 1850, 1850, 1850]$ W de potencia activa y $[0, -1000, 0, 1000, 1000]$ *VAr* de potencia reactiva. Las potencias activas del inversor trifásico de cada uno de los controladores empleados se muestran en la Figura 1.15a y 1.16a.

En la Figura 1.15a es posible evidenciar que todos los controladores empleados presentan un error de estado estacionario en el despacho de potencia activa. Este error se debe a las pérdidas de potencia que existen en las etapas de conversión DC/DC y DC/AC del inversor trifásico. De igual forma, es posible evidenciar que el controlador PI presentó mayor error

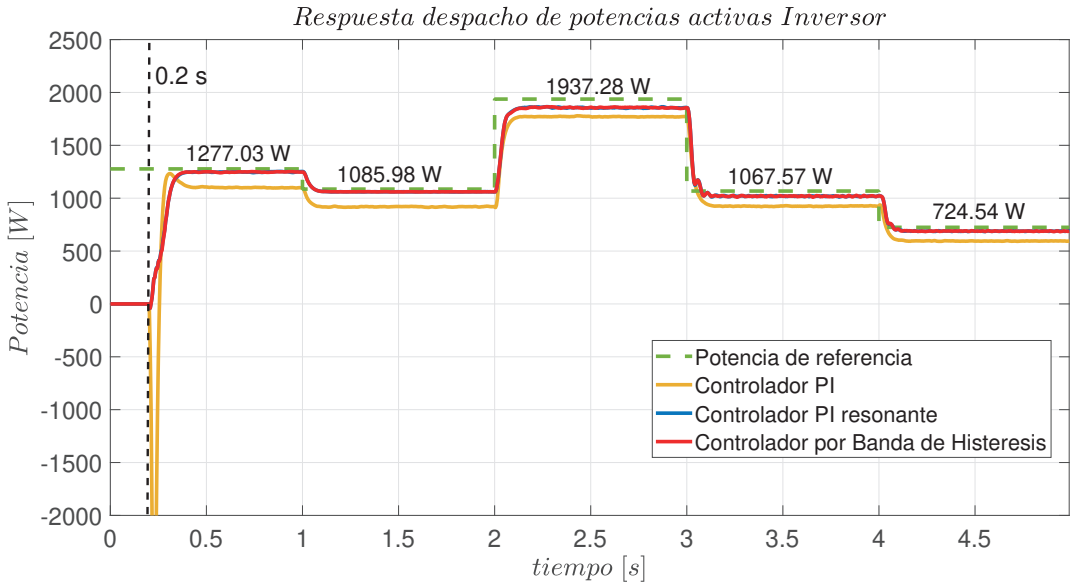

(a) Potencias activas Simulink

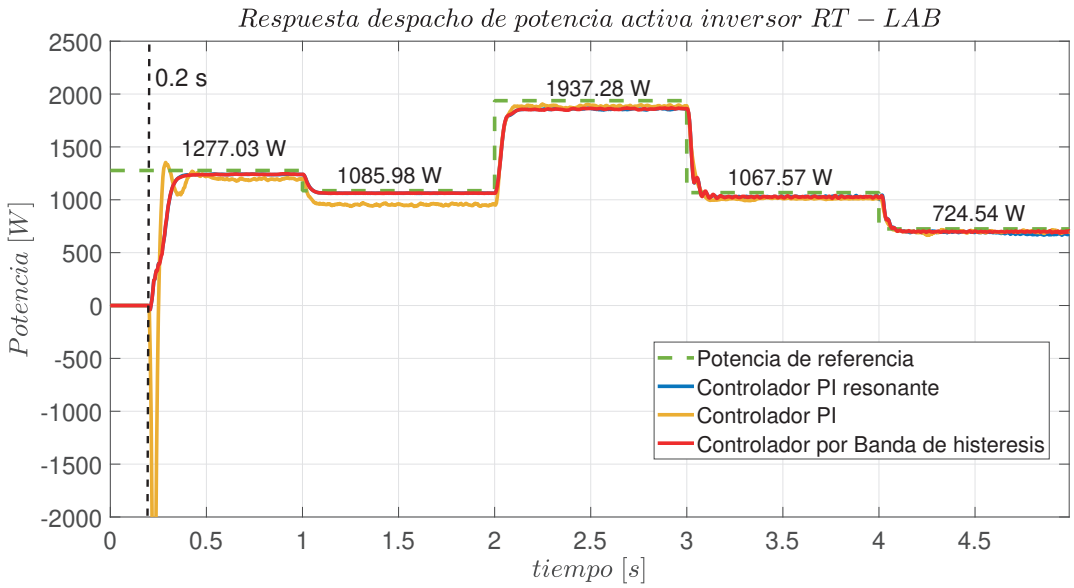

(b) Potencias activas RT-LAB

Figura 1.15: Gráfica de potencias activas vs tiempo del inversor trifásico para cada uno de los controladores empleados en Simulink y en RT-LAB

de estado estacionario que los controladores PI resonante y por banda de histéresis. Por otra parte, en el controlador PI se evidencia un transitorio más pronunciado que en los otros dos controladores. Asimismo, los controladores PI resonante y por banda de histéresis muestran

oscilaciones un poco más pronunciadas en los perfiles de irradiancia 4 y 5 que el controlador PI. Este fenómeno se genera porque estos controladores son más agresivos.

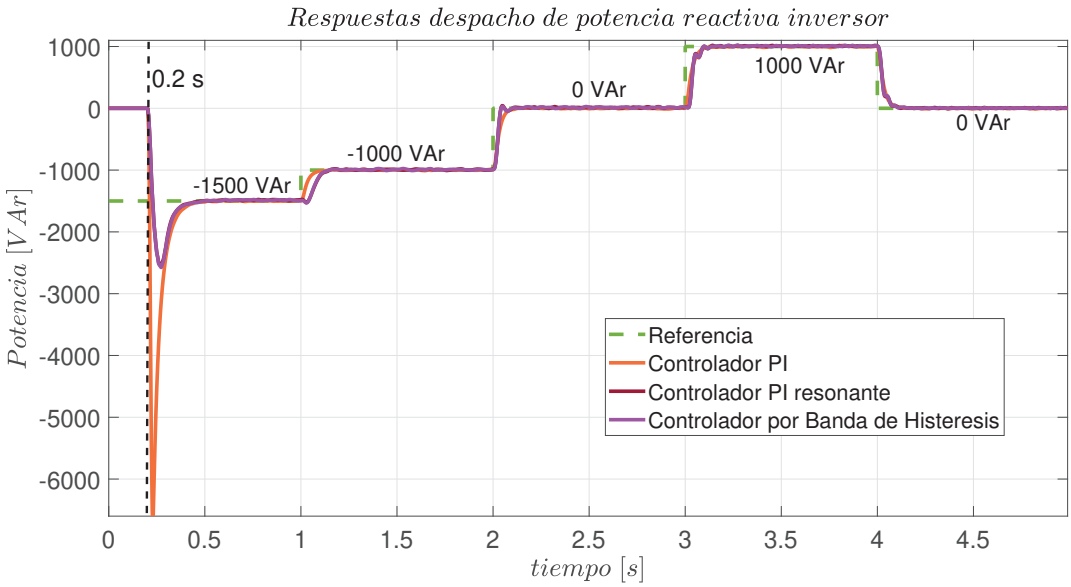

(a) Potencias reactivas Simulink

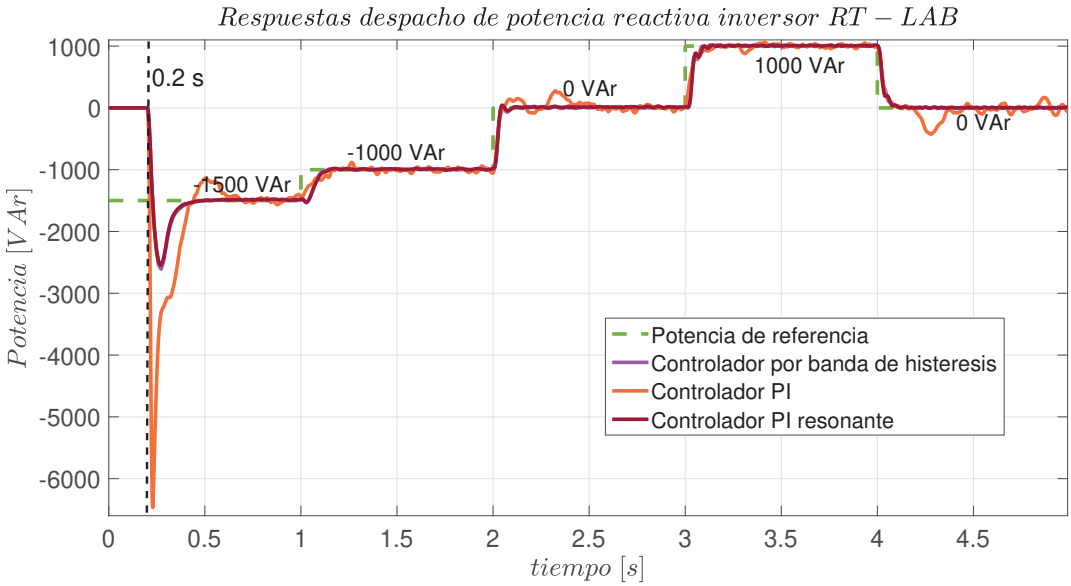

(b) Potencias reactivas RT-LAB

Figura 1.16: Gráfica de potencias reactivas vs tiempo del inversor trifásico para cada uno de los controladores empleados en simulink y en RT-LAB

Ahora, si se examina las respuestas en el despacho de potencia reactiva (Figura 1.16a), se observa que ninguno de los controladores presenta error de estado estacionario. De igual forma, se mira que el controlador PI volvió a tener el transitorio más pronunciado en un inicio, lo que no es deseable para el sistema. Sin embargo, con respecto al tiempo de establecimiento, se nota que el controlador PI presenta un mejor desempeño que los controladores PI resonante y por banda de histéresis. Además, al igual que en el despacho de potencia activa, en el controlador PI se evidencian menores oscilaciones en los perfiles de irradiancia 3, 4 y 5.

No obstante, el análisis elaborado resulta insuficiente para definir el controlador con el mejor desempeño. Por lo tanto, en el presente documento se estudiaron más a fondo las respuestas en potencia activa y reactiva obtenidas de cada uno de los controladores, teniendo en cuenta las siguientes métricas: i) el Error Absoluto Medio (MAE), ii) la integral del error al cuadrado (ISE), iii) la Integral del error al cuadrado multiplicado por el tiempo (ITSE), iv) el Error Cuadrático Medio (MSE) y v) la eficiencia del inversor trifásico con respecto a la máxima potencia activa posible en cada perfil de irradiancia. Los resultados conseguidos se resumen en las Tablas 1.5 y 1.6.

Teniendo en cuenta la Tabla 1.5, el controlador PI presentó los errores más altos y la eficiencia más baja en el seguimiento de la potencia activa del sistema.
Por su parte, el controlador PI resonante muestra el mejor desempeño, ya que obtuvo mejores resultados en 4 de las 5 métricas evaluadas. No obstante, el controlador por banda de histéresis logró un muy buen resultado en el seguimiento de la potencia activa, siendo bastante similar al controlador PI resonante.

Tabla 1.5: Métricas potencia activa

	EAM	**ISE**	**ITSE**	**MSE**	**Eficiencia (%)**
PI	1	1	1	1	86.3385
PI Resonante	**0.5270**	**0.4650**	**0.5007**	**0.4650**	96.1698
Histéresis	0.5272	0.4656	0.5014	0.4656	**96.1980**

Tabla 1.6: Métricas potencia reactiva

	EAM	**ISE**	**ITSE**	**MSE**
PI	1	1	**0.9894**	1
PI Resonante	**0.9502**	**0.8201**	1	**0.8201**
Histéresis	0.9503	0.8203	0.9994	0.8204

Ahora, si se consideran los indicadores de la Tabla 1.6, se evidencia que el controlador PI también presenta el peor desempeño en el seguimiento de la potencia reactiva, puesto que obtuvo los errores más altos en 3 de las 4 métricas analizadas. En contraste, el control PI resonante logró el mejor desempeño en el seguimiento de la potencia reactiva, superó al controlador por banda de histéresis en 3 de los 4 indicadores examinados. Por otra parte, es relevante mencionar que, ala analizar el indicador que ignora la respuesta transitoria del sistema (ITSE), el controlador PI consiguió un menor error que los otros 2 controladores. Esto nos permite deducir que en potencia reactiva el mal desempeño del controlador PI se debe principalmente a su respuesta transitoria.

1.6.2.2 Inversor trifásico bajo PSC variables en RT-LAB: En este escenario el inversor trifásico es sometido a la mismas condiciones planteadas en la sección anterior, cuyas respuestas se presentan en las Figuras 1.15b y 1.16b

En la Figura 1.15b es posible evidenciar que, al igual que en la simulación basada en modelos matemáticos, todos los controladores empleados presentan un error de estado estacionario en el despacho de potencia activa, que está relacionado a las pérdidas de potencia que existen en las etapas de conversión DC/DC y DC/AC del inversor trifásico. De igual forma, se evidencia que los controladores PI resonante y por banda de histéresis no presentaron cambios significativos en las respuestas de potencia activa y reactiva. Sin embargo, el controlador PI sí presentó variaciones representativas, ya que en potencia activa y reactiva el controlador obtuvo mayores oscilaciones, además de un menor error de estado estacionario en la potencia activa. Esto se debe a que el controlador PI, al ser simulado en la plataforma en tiempo real, aumentó considerablemente su agresividad con respecto a los otros 2 controladores, a pesar de que se usa las mismas constantes que en Simulink. Lo anterior, demuestra que la respuesta en una simulación basada en modelos matemáticos no va a ser la misma en la plataforma de simulación en tiempo real, por lo que puede ser necesario una recalibración de los controladores empleados. Por otra parte y al igual que en la sección anterior, se examinaron con más detalle las respuestas en potencia activa y reactiva en RT-LAB, por lo que se vuelve a usar los 5 aspectos (MAE, ISE, ITSE, MSE y la eficiencia), cuyos resultados se resumen en las Tablas 1.7 y 1.8.

La tabla 1.7, muestra que el controlador PI sigue presentando los errores más altos y la eficiencia más baja en el seguimiento de la potencia activa del sistema. Sin embargo, la eficiencia del controlador PI mejoró aproximamente un 7 % con respecto a la simulación en Simulink. Lo anterior, se debe a que el controlador se volvió más agresivo al momento de incorporarlo en RT-LAB. Por otra parte, en RT-LAB el controlador por banda de histéresis superó al controlador PI resonante en todos los aspectos evaluados. Aunque, el controlador PI resonante obtuvo resultados muy similares al controlador por banda de histéresis. Adicionalmente, es clave destacar que la eficiencia del inversor trifásico aumentó en la simulación en tiempo real en los 3 controladores examinados.

Según los indicadores de la Tabla 1.7, se evidencia que el controlador PI volvió a conseguir el peor desempeño en el seguimiento de la potencia reactiva, puesto que obtuvo los errores más altos en las 4 métricas analizadas. De forma semejante al caso de las potencias activas, el control por banda de histéresis logró el mejor desempeño en los 4

Tabla 1.7: Métricas potencia activa RT-LAB

	EAM	ISE	ITSE	MSE	Eficiencia (%)
PI	1	1	1	1	93.8722
PI Resonante	0.8085	0.5437	0.8671	0.5438	96.2906
Histéresis	**0.7923**	**0.5416**	**0.8451**	**0.5416**	**96.4929**

indicadores examinados. Finalmente, es relevante decir que en el saso de la potencia reactiva, el transitorio en el regulador PI sigue siendo la mayor causa de su mal desempeño. Por ello, en el indicador ITSE (Tabla 1.8) los errores de los tres controladores son más cercanos entre sí.

1.6.2.3 Inversor trifásico bajo variaciones de la potencia reactiva: En el presente escenario, el objetivo es establecer la capacidad máxima de potencia reactiva que es capaz de suministrar el inversor. Por lo que, durante los 5 segundos de simulación se establece

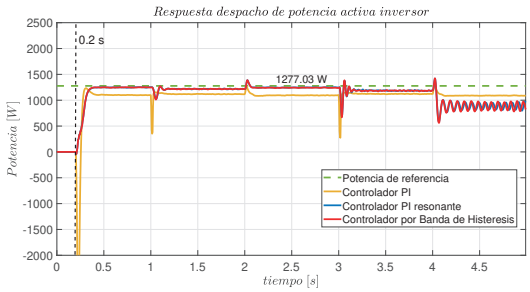

(a) Potencias activas Simulink

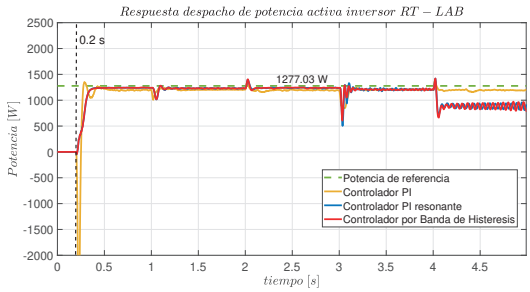

(b) Potencias activas RT-LAB

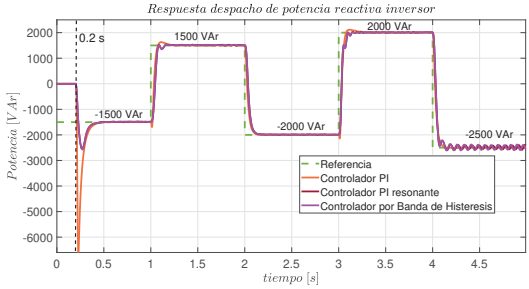

(c) Potencias reactivas Simulink

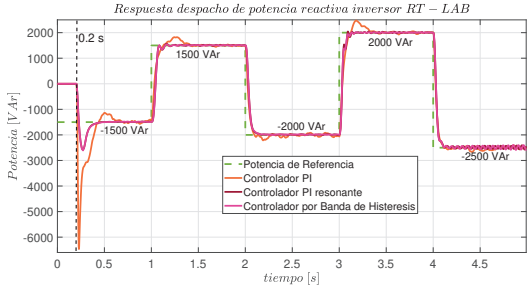

(d) Potencias reactivas RT-LAB

Figura 1.17: Gráficas de potencias activas y reactivas vs el tiempo del inversor trifásico para cada uno de los controladores empleados en el segundo escenario de prueba en Simulink y en RT-LAB

Tabla 1.8: Métricas potencia reactiva RT-LAB

	EAM	ISE	ITSE	MSE
PI	1	1	1	1
PI Resonante	0.8096	0.7482	0.9267	0.7482
Histéresis	**0.8066**	**0.7446**	**0.9213**	**0.7446**

el primer perfil de irradiancia (Tabla 1.3). De igual forma, la potencia reactiva se cambia cada segundo a $[-1500, 1500, -2000, 2000, -2500]$ VAr. Las potencias activas y reactivas de cada uno de los controladores empleados en este escenario se observan en las Figuras 1.17a y 1.17b.

Los resultados señalan que el controlador que permite más despacho de potencia reactiva es el PI, con un rango de despacho de $[-2500, 2500]$ VAr. Asimismo, se evidencia que los controlador PI resonante y por banda de histéresis son capaces de despachar de $[-2000, 2000]$ VAr sin afectar la potencia activa, puntualizando que para valores por fuera

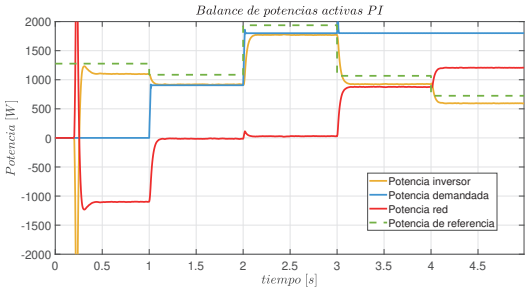

(a) Potencias activas Simulink

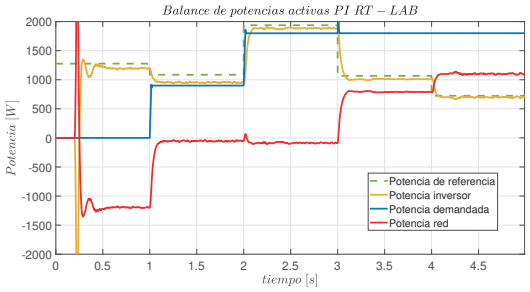

(b) Potencias activas RT-LAB

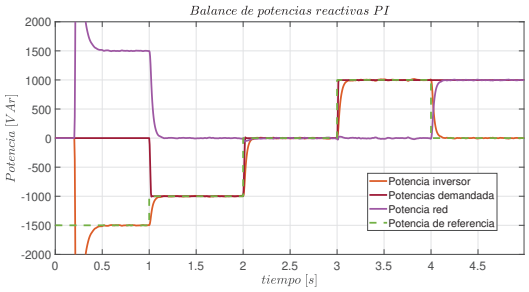

(c) Potencias reactivas Simulink

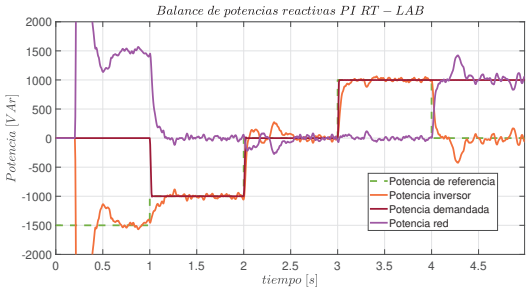

(d) Potencias reactivas RT-LAB

Figura 1.18: Potencias activas y reactivas del inversor, la carga y la red eléctrica para el controlador PI

de ese rango la potencia activa baja y la potencia reactiva presentan oscilaciones significativas como se evidencia en las Figuras 1.17a y 1.17b. Por otra parte, es clave mencionar que la capacidad de despacho de potencia reactiva está relacionada a la agresividad que presentan los controladores; es decir, entre más agresivo sea el controlador, menor despacho de potencia reactiva va a permitir.

1.6.2.4 Inversor trifásico bajo variaciones de la potencia reactiva en RT-LAB: Las respuestas de las potencias activas y reactivas de cada uno de los controladores empleados en la plataforma de simulación en tiempo real se observan en las Figuras 1.17c y 1.17d.

Los resultados obtenidos en RT-LAB en este ítem no cambian mucho con respecto a los resultados conseguidos en la simulación de Simulink, ya que en la plataforma de tiempo real el controlador PI es el que posibilita mayor despacho de potencia reactiva en un rango de $[-2500, 2500]$ VAr, mientras los controladores PI resonante y por banda de histéresis pueden inyectar potencias reactivas en el rango de $[-2000, 2000]$ VAr. Sin embargo, es notable que en RT-LAB el controlador PI presenta una mejor eficiencia en potencia activa y mayores oscilaciones en potencia reactiva.

1.6.2.5 Balance de potencias activas y reactivas: En este escenario se usan los mismos perfiles de irradiancia, las referencias de inyección de potencia reactiva y las potencias

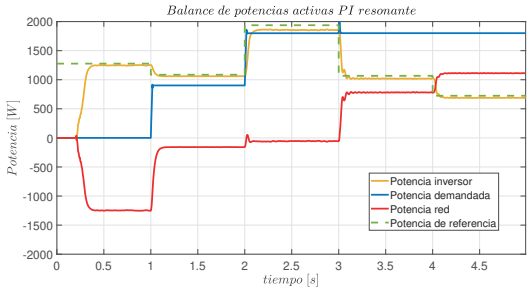

(a) Potencias activas Simulink

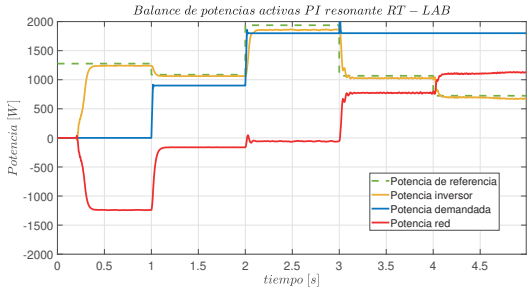

(b) Potencias activas RT-LAB

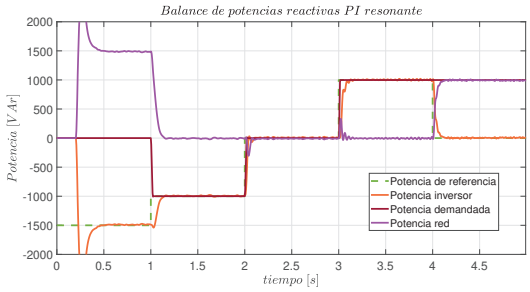

(c) Potencias reactivas Simulink

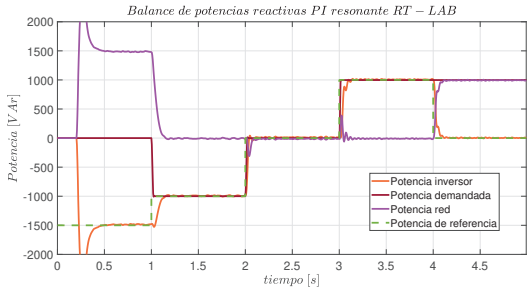

(d) Potencias reactivas RT-LAB

Figura 1.19: Potencias activas y reactivas del inversor, la carga y la red eléctrica para el controlador PI resonante

activas y reactivas demandadas por las cargas del apartado *Inversor trifásico bajo PSC variables en Simulink*. Las potencias activas y reactivas del inversor trifásico, de la carga y la red eléctrica para cada uno de los controladores empleados en Simulink y RT-LAB se muestran en las Figuras 1.18, 1.19 y 1.20.

En las Figuras 1.18a, 1.19a, 1.20a, 1.18c, 1.19c y 1.20c se logra evidenciar que existe un adecuado balance de las potencias activas y reactivas en el sistema, ya que en el intervalo de tiempo de 0.2 s a 1 s se evidencia que, al no presentarse ninguna carga, las potencias activa y reactiva del inversor y la red se compensan en todos los controladores. Ahora, si se examina el intervalo de tiempo 1 s a 3 s, se presentan unas demandas de potencia activa en la carga que son compensadas casi en su totalidad por el inversor en el caso del controlador PI, mientras en los controladores PI resonante y por banda de histéresis se produce un excedente suministrado a la red eléctrica actuando como un sumidero. Con respecto a las potencias reactivas, en el intervalo de tiempo de 1 s a 3 s se observa que la potencia reactiva de la carga es compensada con la potencia reactiva del inversor, por lo que la red casi no inyecta potencia al sistema. Adicionalmente, en el intervalo de tiempo de 3 a 4 segundos se observa que la potencia reactiva de la carga sigue siendo nivelada por el inversor, en tanto la potencia activa de la carga se balancea por medio de la potencia del inversor y la red en todos los controladores. Por último, en el intervalo comprendido de 4 a 5 segundos

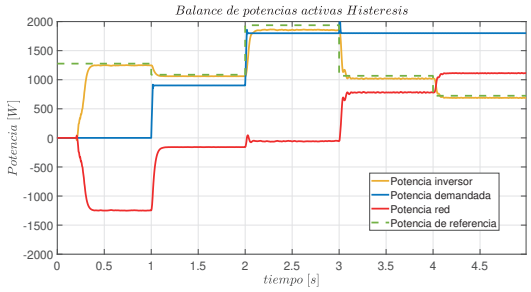

(a) Potencias activas Simulink

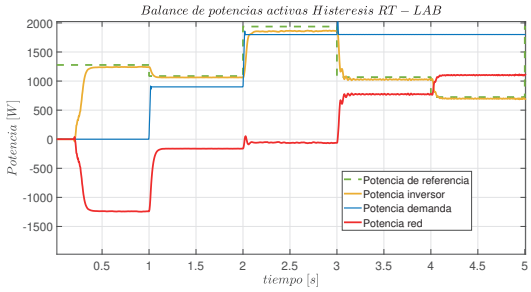

(b) Potencias activas RT-LAB

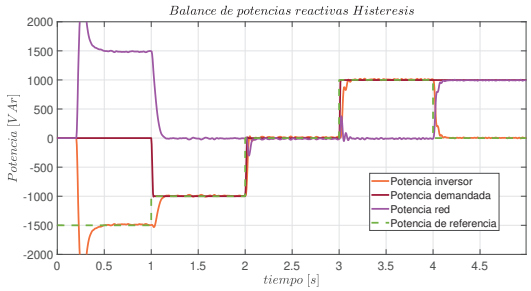

(c) Potencias reactivas Simulink

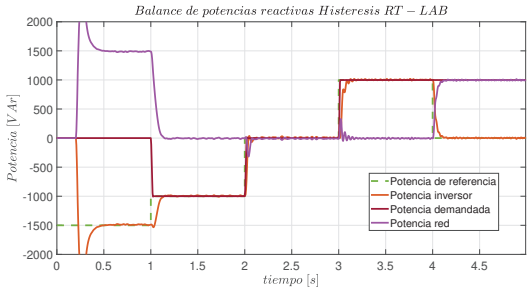

(d) Potencias reactivas RT-LAB

Figura 1.20: Potencias activas y reactivas del inversor, la carga y la red eléctrica para el controlador por banda de Histéresis

se muestra que la potencia reactiva de la carga se nivela en su totalidad por la potencia de la red, ya que no se inyecta potencia reactiva desde el inversor; por otro lado, la potencia activa se compensa por medio de la red eléctrica y el inversor.

1.6.2.6 Balance de potencias activas y reactivas en RT-LAB: Si se tienen en cuenta las Figuras 1.18b, 1.19b, 1.20b, 1.18d, 1.19d y 1.20d, se observa que en la plataforma en tiempo real sigue manteniéndose un correcto balance en las potencias activas y reactivas. Sin embargo, es destacable mencionar que el cambio más significativo se presenta en el controlador PI, en el cual se evidencian oscilaciones considerables en potencia reactiva (Figuras 1.18c, 1.18d). A pesar de este fenómeno, la potencia de la carga es completamente compensada por la red eléctrica, verificando el correcto funcionamiento del modelo en la plataforma de simulación en tiempo real.

1.7 Limitaciones y trabajo futuro

Las principales limitaciones del trabajo presentado en este capítulo se centran en el alcance de la validación del inversor trifásico implementado, puesto que se llevó a cabo mediante simulaciones basadas en modelos matemáticos y en una plataforma de simulación de tiempo real Opal-RT, bajo condiciones ambientales rigurosas, como variaciones en la irradiancia de la generación y fluctuaciones en la demanda de las cargas en un esquema de control en SIL, sin embargo no se considera variaciones e incertidumbres propias del sistema físico como las corrientes de fuga, corrientes y tensiones desequilibrados y perdidas por conmutación de los semiconductores. De igual forma, no se examinó el sistema en presencia de cargas altamente no lineales como los variadores de velocidad, dispositivos que pueden contribuir a la inestabilidad de los controladores y la formación de armónicos.

Como trabajo futuro, se propone la implementación del inversor trifásico en un esquema de control en HIL (*Hardware in the Loop*) que posibilite mitigar las variaciones e incertidumbres propias del sistema, además de validar las técnicas de control en un sistema mucho mas cercano a la realidad. Así mismo, se recomienda efectuar alguna mejora en el modelo que emula el sombreado parcial incorporando la temperatura en la función de costo. Esto permitirá una aproximación mucho mas fiable del comportamiento real de la celda fotovoltaica bajo condiciones climáticas desafiantes lo que incrementaría la efectividad del controlador GMPPT.

1.8 Conclusiones

En este capítulo se presenta la implementación de un inversor solar trifásico conectado a la red que es capaz de mitigar las PSC y controlar la potencia reactiva inyectada a la red. El inversor realizado está compuesto por un arreglo de 6 módulos fotovoltaicos conectados en serie, un convertidor DC/DC, un regulador GMPPT híbrido, un controlador por superficie de deslizamiento y un convertidor DC/AC NPC de 2 niveles. Adicionalmente, se elaboraron y compararon 7 algoritmos GMPPT híbridos capaces de encontrar el punto GMPP. Asimismo,

se realizaron 3 controladores que posibilitan la gestión de las potencias activa y reactiva del inversor trifásico. Las estrategias de control se validan en simulaciones basadas en modelos matemáticos y en una plataforma de simulación de tiempo real Opal-RT, ante condiciones ambientales exigentes como variaciones en la irradiancia desde la generación y cambios en la demanda desde las cargas en un esquema de control en SIL, obteniendo los siguientes resultados principales.

Primero, se realizó un análisis detallado de los algoritmos GMPPT híbridos y se encontró que el mejor algoritmo fue el wPSO. Segundo, se diseñó y sintonizó un controlador por modos deslizantes que posibilitó regular la corriente y el voltaje en el convertidor DC/DC. Tercero, el inversor propuesto se analizó matemática y numéricamente mediante simulaciones realizadas en Simulink y en una plataforma de simulación en tiempo real, encontrando que el controlador PI resonante presenta la mejor eficiencia en potencia activa en Simulink, mientras en la plataforma de tiempo real fue el controlador por banda de histéresis. Cuarto, se estableció que el controlador para el inversor que permite el mayor despacho de potencia reactiva en Simulink y en la plataforma de simulación en tiempo real fue el PI. Quinto, se evaluó y verificó el adecuado balance de potencias del inversor, la carga y la red eléctrica para todos los controladores simulados en Simulink y en la plataforma de simulación en tiempo real.

CAPÍTULO 2

CONTROL SECUNDARIO: ANÁLISIS COMPARATIVO DE TÉCNICAS DE CONTROL SECUNDARIO

2.1 Resumen

En una microrred aislada, es común enfrentarse a fenómenos transitorios, como cambios abruptos en la demanda de energía por parte de las cargas o fallos en las fuentes de generación, que pueden afectar la calidad del suministro eléctrico. Este capitulo se centra en evaluar el rendimiento de sistemas de control tanto centralizados como distribuidos para operar inversores de red en una microrred trifásica aislada. Se propone un controlador centralizado de tipo MRAC, utilizando redes neuronales de tipo NARX, junto con un método para ajustar los parámetros de los controladores primarios y secundarios mediante una técnica heurística de enjambre de partículas modificada (DEPSO).

2.2 Introducción

Las microrredes eléctricas (MG) se han propuesto como una forma de abordar la transformación energética maximizando la eficiencia de los recursos renovables. Una microrred es un sistema de energía integrado que consta de cargas y recursos energéticos que se distribuyen dentro de límites eléctricos definidos y que actúan como una planta controlable [38], [42]. La inclusión de generadores distribuidos (GDs) presenta un desafío en microrredes aisladas, los cuales generalmente se controlan y se conectan a la microrred a través de inversores *on-grid*

y *off-grid*. Así, el lazo de control de estos dispositivos debe garantizar la estabilidad del sistema, satisfacer la carga de la microrred, mantener la calidad de la energía y suministrar la potencia requerida [38]. Además, requiere del control de variables importantes para la estabilidad del sistema, tales como la frecuencia y el voltaje.

Para garantizar el funcionamiento óptimo de las microrredes, se aplican esquemas de control jerárquico [39], los cuales se dividen en tres niveles de control [40]. El primer nivel consiste en un bucle de control local de corriente y tensión, diseñado para asegurar una distribución eficiente de energía y controlar la tensión y la frecuencia de cada generador [41]. No obstante, ante la presencia de anomalías, el controlador local suele no ser capaz de garantizar la estabilidad de la frecuencia y la tensión [42].

El segundo nivel de control se utiliza para corregir las desviaciones en la frecuencia y la tensión mediante el ajuste de los valores preseleccionados de las corrientes de los generadores distribuidos del primer nivel, con el fin de cumplir con los requisitos técnicos de la microrred [42]. Además, facilita el intercambio de energía entre los generadores. Por último, el tercer nivel se encarga de optimizar y gestionar el flujo de energía entre los MGs. Por lo general, se requieren controladores descentralizados y centralizados para los niveles primario y terciario, respectivamente, mientras que el nivel secundario puede implementarse utilizando ambas estructuras.

En cuanto a las microrredes reales, experimentan fenómenos transitorios como cambios abruptos en la demanda de energía y fallas en las fuentes de generación, lo que provoca perturbaciones e incorporación de generadores distribuidos adicionales. Esto conlleva a grandes variaciones en el voltaje y la frecuencia, así como a un aumento en las distorsiones armónicas, lo que afecta la estabilidad y la calidad de la energía. Estos factores pueden hacer que el sistema no cumpla con los requisitos técnicos de las microrredes AC [43].

Se han realizado numerosos estudios para abordar estas problemáticas. Por ejemplo, en [44], se propone un controlador centralizado basado en reguladores PI para mejorar el comportamiento dinámico y estacionario de la tensión y la frecuencia del sistema [42]. Sin embargo, este enfoque presenta limitaciones en la red de comunicación, lo que aumenta la sensibilidad del sistema a fallos y reduce su fiabilidad. Para superar estas restricciones, han surgido controladores descentralizados [45]-[50], que permiten una comunicación más robusta entre las unidades, mejorando así la fiabilidad del sistema y la independencia de cada generador [51]-[54]. No obstante, este enfoque requiere un sistema de comunicación más complejo para gestionar la información de todas las unidades de generación [42].

En respuesta a la dificultad de establecer una red de datos altamente demandante de recursos, se crearon los controladores distribuidos que se han empleado para reducir la compleja red de comunicación de los controladores descentralizados. Esto incrementa la independencia de cada generador y aumenta la confiabilidad del sistema. En [55] y [56], los autores presentan el control secundario distribuido estocástico y con retardo de tiempo de una microrred que restaura la frecuencia y la tensión. El efecto de los retrasos en las comunicaciones sobre el control secundario de la microrred en modo isla se ha investigado mediante un modelo de pequeña señal en [57], [58]. Por su parte, los efectos de

las perturbaciones, las incertidumbres y la dinámica no modelada en el controlador de la microrred aislada se reportan en [59] y [60].

Para las microrredes altamente no lineales y complejas, los esquemas de control basados en técnicas de inteligencia artificial, como la lógica difusa, las redes neuronales (NN) y los algoritmos evolutivos, están ganando un gran interés [61]. Los controladores inteligentes son prometedores porque pueden adaptarse a las incertidumbres y pueden utilizarse también cuando no se dispone del modelo del sistema a controlar. Recientemente, las redes neuronales con capacidad de aprendizaje se aplican ampliamente para el control de sistemas de potencia complejos. Por ejemplo, en [62], se desarrolla un controlador basado en lógica difusa para la regulación de voltaje y frecuencia mediante el ajuste de controladores PI. Igualmente, en [63] se elabora un controlador inteligente neurodifuso adaptativo para regular la distribución de frecuencia y energía entre las unidades de GD en una microrred AC, el cual mantiene la estabilidad del sistema en condiciones ambientales severas y cambios en la carga.

Asimismo, se han desarrollado técnicas que emplean únicamente redes neuronales, como en [64], donde se diseña un controlador empleando redes de tiempo discreto para el control de un sistema de distribución de corriente continua. Igualmente, en [65] se propone un controlador de modo deslizante basado en una red neuronal RBF (Radial Basis Function Networks) para eliminar la desviación de voltaje causada por el control primario en una microrred en modo isla. El artículo destaca la realización de pruebas de funcionamiento convencionales, como el cambio de la referencia del voltaje en el punto de acople común (PCC).

Tras una exhaustiva revisión bibliográfica, se observa que la mayoría de los estudios analizados comparan dos o tres tipos de controladores secundarios. Asimismo, se nota que los métodos sugeridos en los documentos revisados raramente son sometidos a condiciones eléctricas extremas, como la conexión o desconexión de un Generador Distribuido (GD).

Considerando este contexto, este capítulo se enfoca en investigar la estabilidad, el control del voltaje y la regulación de la frecuencia en el Punto de Conexión Común (PCC) de una microrred que consta de múltiples GDs. Las estrategias propuestas son validadas bajo condiciones variables de carga, fallos en las fuentes de energía o la adición de nuevos GDs.

El contenido de este capitulo comprende los siguientes aspectos:

- Un modelo matemático de una microrred implementada en una red IEEE de 13 nodos modificada.

- Una función de costo que permite optimizar los parámetros de calibración de los controladores, con el fin de garantizar la estabilidad y un bajo error de estado estacionario en voltaje y frecuencia.

- Un control secundario basado en redes neuronales capaces de regular la tensión y frecuencia del bus de AC sin necesidad de un modelo matemático del sistema.

- Una comparativa de 8 controladores secundarios bajo condiciones abruptas de variación de carga y fallas imprevistas en los GDs.
- La validación de los controladores mediante la incorporación de escenarios que generen altas variaciones en la magnitud de voltaje y frecuencia, además de un aumento en las distorsiones armónicas de la microrred en una plataforma de simulación en tiempo real OPAL-RT.

2.3 Modelo propuesto de la red aislada

Una unidad típica de generación distribuida (GD) suele estar formada por una fuente principal de DC, un convertidor DC/AC (Inversor) y un filtro LCL, como se muestra en la Figura 2.1, donde también se presentan las bases de control del sistema.

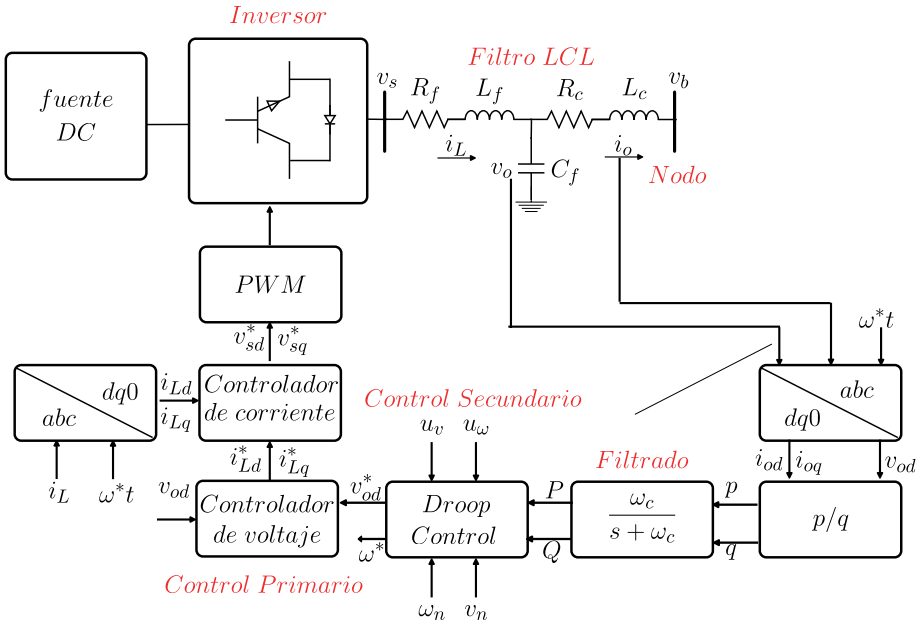

Figura 2.1: Esquema general de una GD

2.3.1 Cálculo filtro LCL

El filtro LCL tiene como principal objetivo eliminar los armónicos de alta frecuencia generados por la conmutación de los semiconductores y, de esta forma, inyectar a la red eléctrica una señal de voltaje adecuada que posibilite mejorar la calidad de la energía y la estabilidad del sistema. El procedimiento de diseño parte del conocimiento de los parámetros de operación del sistema como la potencia nominal (P_n), la frecuencia de conmutación del

convertidor (f_{sw}), el voltaje fase a neutro de la red (v_n) y la frecuencia fundamental de la red (f_n), así como valores base, a partir de los cuales se calculan la impedancia base (Z_b), la inductancia base (L_b) y la capacitancia base (C_b), dadas por [66]:

$$Z_b = \frac{v_n^2}{P_n}, \quad L_b = \frac{Z_b}{2\pi f_n}, \quad C_b = \frac{1}{2\pi f_n Z_b}. \tag{2.1}$$

Ahora, se diseña el inductor L_f con el fin de reducir el rizado en la corriente generada por el inversor mediante:

$$L_f = \frac{V_{dc}}{3\sqrt{3}\Delta I_{max} f_{sw}}$$
$$\Delta I_{max,ks} = k_s \frac{P_n\sqrt{2}}{3v_n},$$

donde V_{dc} es el voltaje de entrada del inversor y k_s es una constante que indica el porcentaje de atenuación que frecuentemente se utiliza entre 0.1 y 0.2.

El valor del capacitor también tiene influencia en el rizado de la corriente, por lo que se recomienda establecer un factor menor o igual al 5 % cuando se requiere compensar la reactancia inductiva del filtro. El capacitor C puede ser encontrado con [66]:

$$C \leq 0.05 C_b. \tag{2.2}$$

Luego, se calcula el inductor del lado de la red (L_c), cuyo propósito es atenuar la distorsión armónica a los límites establecidos por los estándares de calidad. El valor de L_c es:

$$L_c = \frac{\frac{1-k_g}{k_g}}{2\pi {f_{sw}}^2 C - \frac{1}{L_f}}, \tag{2.3}$$

El factor de atenuación k_g representa la relación entre la fluctuación de la corriente inyectada a la red i_o y la fluctuación de la corriente de salida del inversor i_L. Es crucial destacar que la suma máxima de la inductancia combinada $L_f + L_c$ debe ser restringida. Se sugiere que este valor máximo no supere el $10\,\%$ de la inductancia base, es decir:

$$L_f + L_c \leq 0.1 L_b. \tag{2.4}$$

Una vez que los parámetros del filtro han sido seleccionados, es necesario verificar que la frecuencia de resonancia

$$f_{res} = \frac{1}{2\pi}\sqrt{\frac{L_f + L_c}{L_f L_c C}} \tag{2.5}$$

se encuentra dentro del rango

$$10 f_n < f_{res} < 0.5 f_{sw}, \tag{2.6}$$

a fin de evitar problemas de resonancia e inestabilidad.

2.3.2 Rastreo de fase y frecuencia PLL

El PLL es un control de lazo cerrado que rastrea la fase y frecuencia de una señal trifásica. El controlador usado en este modelo está adaptado de la librería de Simulink [32] y tiene la composición ilustrada en la Figura 2.2.

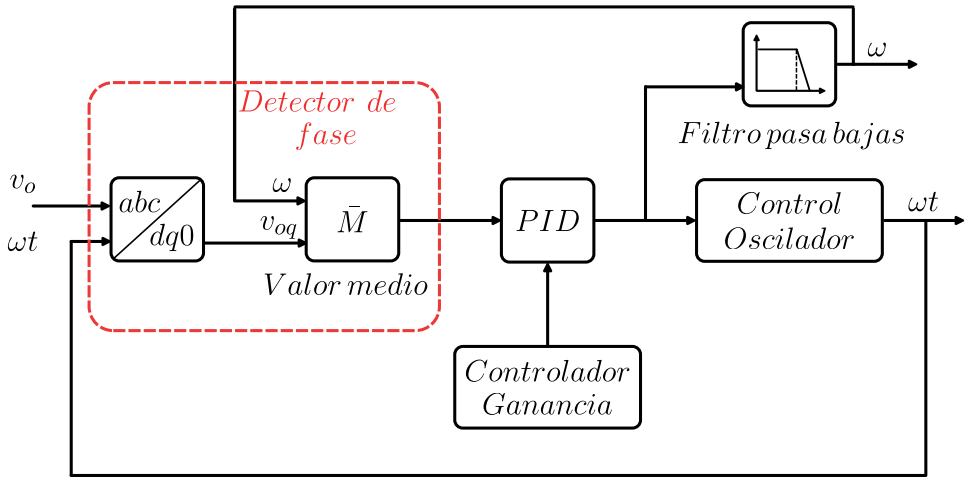

Figura 2.2: Estructura interna de un PLL, modificado de [32]

La señal de entrada trifásica se transforma en un marco giratorio $dq0$, conocido como la transformada de Park, utilizando la frecuencia angular retroalimentada ω, donde ωt representa la frecuencia angular integrada $\omega t = \int \omega dt$. Dado que el objetivo es alinear el vector de tensión en $dq0$ con el eje d para anular la componente q, se descarta la primera componente de la tensión .

Seguidamente, el eje cuadrado de la señal, proporcional a la diferencia de fase entre la señal abc y el marco giratorio del oscilador interno, se suaviza mediante un filtro de media (de frecuencia variable). Luego, un controlador Proporcional-Integral-Derivativo (PID), equipado con un control automático de ganancia (AGC), mantiene la diferencia de fase en cero al influir sobre un oscilador controlado. La salida del PID, que corresponde a la velocidad angular, se filtra y convierte en frecuencia en Hz, utilizando el valor medio.

Este controlador se usará para obtener la frecuencia para aquellos controladores que dependan de un punto de acople común (PCC), así como para medir la frecuencia en el resto de nodos que no cuenten con generación eléctrica.

2.3.3 Generador de pulsos PWM

El generador de pulsos del modelo se adapta de la librería de Simulink [35] y se usa para controlar los dispositivos de conmutación (FET, GTO o IGBT) en el convertidor trifásico. La señal de referencia, también llamada señal de modulación, se compara con una portadora triangular simétrica de $5\ kHz$. Cuando la señal de referencia es mayor que la portadora, el

pulso para el dispositivo de conmutación superior es alto (1) y el pulso para el dispositivo inferior es bajo (0).

El PLL y el generador de PWM forman parte del bolque inversor de la Figura 2.1 y se incluyen en la descripción por ser partes importantes de este bloque principal.

2.3.4 Modelo de espacio de estados

En una microrred aislada que cuenta con varios Generadores Distribuidos (GDs), la estabilidad de la tensión y la frecuencia del bus son mantenidas por las unidades de generación. Además, se asume que la carga de potencia se distribuye entre los GDs según su capacidad nominal. Al contemplar el sistema descrito en la Figura 2.1, la potencia de salida filtrada medida de cada generador en coordenadas dq puede ser representada como se describe en [117]:

$$P = \frac{3}{2}\left(v_{od}i_{od} + v_{oq}i_{oq}\right)\frac{\omega_c}{s+\omega_c} \tag{2.7}$$

$$Q = \frac{3}{2}\left(v_{oq}i_{od} - v_{od}i_{oq}\right)\frac{\omega_c}{s+\omega_c}, \tag{2.8}$$

donde ω_c representa la frecuencia de corte del filtro de paso bajo y v_{od}, v_{oq}, i_{od} e i_{oq} son las tensiones y corrientes de salida del generador en el marco de referencia dq. Así, el modelo dinámico de pequeña señal del control de potencia viene dado por:

$$\dot{P} = -P\omega_c + \frac{3}{2}\omega_c\left(v_{od}i_{od} + v_{oq}i_{oq}\right), \tag{2.9}$$

$$\dot{Q} = -Q\omega_c + \frac{3}{2}\omega_c\left(v_{oq}i_{od} + v_{od}i_{oq}\right). \tag{2.10}$$

Dado que cada GD se controla bajo su propia coordenada dq, se necesita una coordenada común para formular las ecuaciones de red del sistema global. En este documento, el GD_1 se elige como la común, de modo que la diferencia de fase de cada coordenada de GD puede expresarse como:

$$\dot{\delta}_i = \omega_i - \omega_1, \text{ para } i = \{2, 3, \ldots, N\}. \tag{2.11}$$

Según la estructura de las líneas de transmisión en microrredes representada en la Figura 2.3, las dinámicas del filtro LCL pueden ser descritas mediante

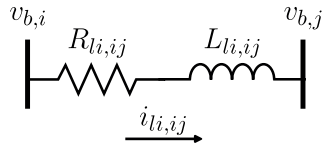

Figura 2.3: Estructura de las líneas de transmisión entre nodos

$$
\begin{aligned}
L_{li,ij}\frac{d}{dt}\begin{bmatrix} i_{liD,ij} \\ i_{liQ,ij} \end{bmatrix} &= \begin{bmatrix} v_{oD,i} \\ v_{oQ,i} \end{bmatrix} - \begin{bmatrix} v_{oD,j} \\ v_{oQ,j} \end{bmatrix} \\
&- \begin{bmatrix} R_{li,ij} & -\omega_1 L_{li,ij} \\ \omega_1 L_{li,ij} & R_{li,ij} \end{bmatrix} \begin{bmatrix} i_{liD,ij} \\ i_{liQ,ij} \end{bmatrix},
\end{aligned} \tag{2.12}
$$

donde $R_{li,ij}$ y $L_{li,ij}$ son la resistencia y el inductor de la línea de transmisión, $i_{lineD,ij}/i_{lineQ,ij}$ y v_{oD}/v_{oQ} son la corriente de la línea y la tensión del bus en coordenadas comunes. Estas variables tienen relación de transformación con las variables bajo la coordenada dq del GD i-ésimo, dado por [67]

$$
\begin{bmatrix} v_{oD} \\ v_{oQ} \end{bmatrix} = T(\delta_i) \begin{bmatrix} v_{od} \\ v_{oq} \end{bmatrix}, \qquad T(\delta) \quad = \begin{bmatrix} \cos\delta & -\sin\delta \\ \sin\delta & \cos\delta \end{bmatrix} \tag{2.13}
$$

$$
\begin{bmatrix} i_{lid,ij} \\ i_{liq,ij} \end{bmatrix} = T^{-1}(\delta) \begin{bmatrix} i_{liD,ij} \\ i_{liQ,ij} \end{bmatrix}, \; T^{-1}(\delta) = \begin{bmatrix} \cos\delta & \sin\delta \\ -\sin\delta & \cos\delta \end{bmatrix}. \tag{2.14}
$$

Sustituyendo (2.13) en (2.12), se obtiene la dinámica de $i_{liD,ij}/i_{liQ,ij}$ descrita por las variables v_{od}/v_{oq}. A continuación, al utilizar la transformación mostrada en (2.14), se encuentra la dinámica del inductor de línea bajo la coordenada dq del GD i-ésimo para encontrar las dinámicas de la corriente de salida i_{od}/i_{oq}.

Ignorando las dinámicas del transistor, las tensiones de referencia que salen del transistor v^*_{sd}/v^*_{sq} y la frecuencia de referencia ω^* pueden considerarse como las señales ideales calculadas v_{sd}/v_{sq} y ω_i. Entonces, la dinámica del filtro puede expresarse como:

$$
L_f\frac{d}{dt}\begin{bmatrix} i_{Ld} \\ i_{Lq} \end{bmatrix} = \begin{bmatrix} v_{sd} \\ v_{sq} \end{bmatrix} - \begin{bmatrix} v_{od} \\ v_{oq} \end{bmatrix} - \begin{bmatrix} R_f & -\omega L_f \\ \omega_i L_f & R_f \end{bmatrix} \begin{bmatrix} i_{Ld} \\ i_{Lq} \end{bmatrix} \tag{2.15}
$$

$$
C_f\frac{d}{dt}\begin{bmatrix} v_{od} \\ v_{oq} \end{bmatrix} = \begin{bmatrix} i_{Ld} \\ i_{Lq} \end{bmatrix} - \begin{bmatrix} i_{od} \\ i_{oq} \end{bmatrix} - \begin{bmatrix} 0 & -\omega C_f \\ \omega C_f & 0 \end{bmatrix} \begin{bmatrix} v_{od} \\ v_{oq} \end{bmatrix} \tag{2.16}
$$

$$
L_c\frac{d}{dt}\begin{bmatrix} i_{od} \\ i_{dq} \end{bmatrix} = \begin{bmatrix} v_{od} \\ v_{oq} \end{bmatrix} - \begin{bmatrix} v_{bd} \\ v_{bq} \end{bmatrix} - \begin{bmatrix} R_c & -\omega L_c \\ \omega L_c & R_c \end{bmatrix} \begin{bmatrix} i_{od} \\ i_{oq} \end{bmatrix}, \tag{2.17}
$$

donde R_f, R_c, L_f y L_c son las resistencias e inductancias internas del filtro, respectivamente.

El controlador de este sistema se basa en varios niveles de control que darán las señales de referencia de $\omega^*, v^*_{od}, v^*_{sd}$ y v^*_{sq} necesarias. Los niveles de control se detallarán en las siguientes secciones, comenzando por el control de *Droop*.

2.3.5 Control Droop

La base del control de GDs es el control de *droop*, cuyo funcionamiento se rige en la relación existente entre la tensión, la frecuencia y las potencias. Estas variables, tal como se muestra en la Figura 2.4, poseen una relación de inversa proporcionalidad entre ellas.

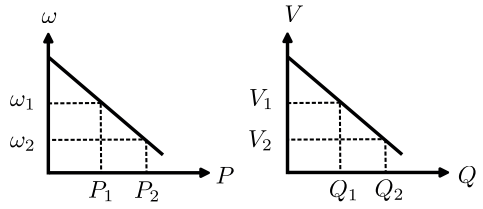

Figura 2.4: Curvas características de frecuencia ω y voltaje v en relación con la potencia activa y reactiva (P, Q)

Teniendo en cuenta la relación mostrada en Figura 2.4, el controlador tipo *droop* permite generar las referencias de frecuencia ω^* y voltaje v_{od}^* dados por [68]:

$$\begin{aligned} \omega^* &= \omega_n - R_p P \\ v_{od}^* &= v_n - R_q Q \\ v_{oq}^* &= 0, \end{aligned} \tag{2.18}$$

donde ω_n y v_n son la frecuencia y la tensión nominal, ω^* y v_{od}^*/v_{oq}^* son las referencias de la frecuencia y la tensión de salida para el lazo de control interno, P y Q son la potencia activa de salida y la potencia reactiva filtrada de los GDs, y R_p y R_q son los coeficientes de *droop* de frecuencia y de tensión, respectivamente. Los coeficientes de $droop$ se calculan teniendo en cuenta la relación de la Figura 2.4, mediante

$$R_q = \frac{v_{max} - v_{min}}{Q_{max} - Q_{min}}, \tag{2.19}$$

$$R_p = \frac{\omega_{max} - \omega_{min}}{P_{max} - P_{min}}, \tag{2.20}$$

donde v_{max} y v_{min} son los valores máximos y mínimos de tensión permitidos para el controlador de $droop$, siendo $P_{max}, P_{min}, Q_{max}$ y Q_{min} los rangos permitidos en potencia para el controlador. Estos valores normalmente se calculan teniendo en cuenta la demanda de la red, la generación de los diferentes GDs y el margen de funcionamiento que se le quiera dar al controlador. Sin embargo, es importante tener en cuenta que entre mayor sea el rango de funcionamiento, es más probable que llegue al valor deseado de tensión y voltaje, pero tendrá un error de estado estacionario más alto y mayores transitorios [68].

Cabe mencionar que este control es importante porque le dará los valores de referencia de tensión y frecuencia al control primario para su funcionamiento.

2.3.6 Control primario

Está compuesto por dos lazos de control independientes que operan con las transformadas dq de tensión y corriente. A su vez, como se muestra en Figura 2.5, los controladores constan de dos controladores tipo PI en cascada, los cuales se encargan de la regulación de tensión y corriente.

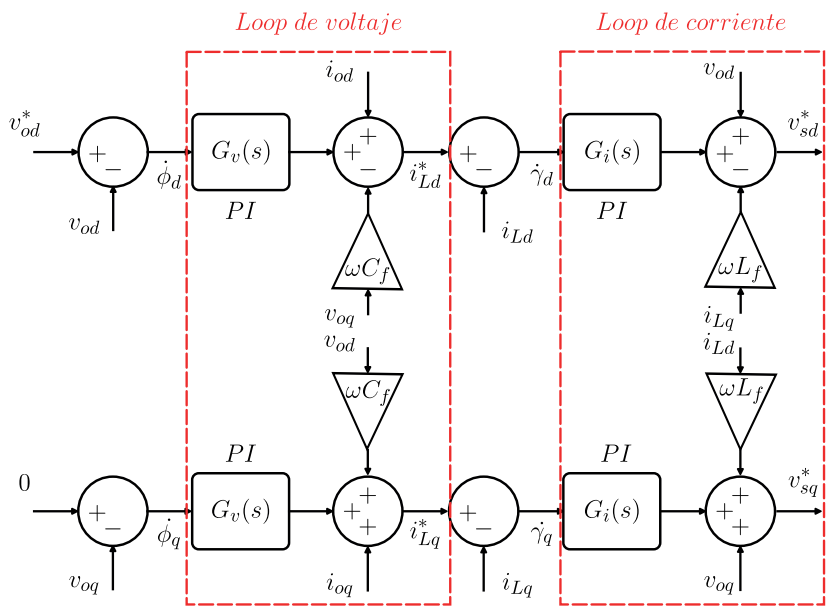

Figura 2.5: Esquema del control primario

Como se puede observar en Figura 2.5, el lazo de control de voltaje en coordenadas dq se define por:

$$i_{Ld}^* = k_{IV}\phi_d + k_{PV}\dot{\phi}_d - \omega_n C_f v_{oq} + i_{od} \tag{2.21}$$

$$i_{Lq}^* = k_{IV}\phi_q + k_{PV}\dot{\phi}_q + \omega_n C_f v_{od} + i_{oq}, \tag{2.22}$$

donde $\dot{\phi}_d = v_{od}^* - v_{od}$, $\dot{\phi}_q = v_{oq}^* - v_{oq}$ mientras que k_{PV} y k_{IV} son los coeficientes proporcional e integral, respectivamente.

En cuanto al lazo de control de corriente, sus dinámicas se expresan como

$$v_{sd}^* = k_{IC}\gamma_d + k_{PC}\dot{\gamma}_d - \omega_n L_f i_{Lq} + v_{od} \tag{2.23}$$

$$v_{sq}^* = k_{IC}\gamma_q + k_{PC}\dot{\gamma}_q + \omega_n L_f i_{Ld} + v_{oq}, \tag{2.24}$$

donde $\dot{\gamma}_d = i_{Ld}^* - i_{Ld}$, $\dot{\gamma}_q = i_{Lq}^* - i_{Lq}$ mientras que k_{PC} y k_{IC} son los coeficientes proporcional e integral, respectivamente.

Finalmente, con las ecuaciones de los controladores se puede obtener el modelo completo de pequeña señal del sistema, el cual se describe mediante las variables de estado del sistema:

$$\begin{aligned} x_s = [&\delta,\ P,\ Q,\ \phi_d,\ \phi_q,\ \gamma_d, \gamma_q,\ i_{Ld},\ i_{Lq},\ v_{od},\ v_{oq}, \\ &i_{od},\ i_{oq},\ i_{loadD},\ i_{loadQ},\ i_{liD},\ i_{liQ}]^T, \end{aligned}$$

con $x_s \in \mathbb{R}^{17}$ y tiene como entradas los voltajes de nodo v_{bD} y v_{bQ}.

Dado que las tensiones de los nodos v_b se utilizan como entrada al sistema, los efectos de la perturbación de la carga no pueden predecirse con exactitud. En la práctica, la única perturbación que se produce en el sistema procede del cambio escalonado de la carga [67]. Por lo tanto, se necesita un método para incluir los términos relativos a las tensiones de los nodos de la MG. De este modo, las entradas definidas en el modelo se obtienen en función de las corrientes de la GD, suponiendo una resistencia virtual de alta impedancia conectada al bus del inversor [67]. Esta resistencia r_n se conecta como se muestra en la Figura 2.6, teniendo un impacto insignificante en la dinámica del sistema con un valor nominal de $1000\ \Omega$. Mediante el uso de la ley de voltaje de Kirchhoff, las ecuaciones que describen la tensión del bus en función de las corrientes de carga y corrientes de línea pueden expresarse como:

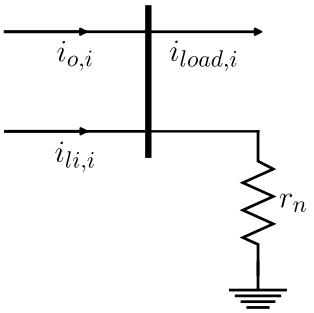

Figura 2.6: Resistencia virtual en el bus de un GD

$$v_{bD} = r_n \left(i_{oD} + i_{liD} - i_{loadD} \right) \tag{2.25}$$
$$v_{bQ} = r_n \left(i_{oQ} + i_{liQ} - i_{loadQ} \right). \tag{2.26}$$

2.3.7 Control secundario

Se recurre al control secundario para contrarrestar la influencia de la impedancia de la línea de transmisión en la distribución de potencia y para compensar las desviaciones de tensión y frecuencia ocasionadas por el control de caída de tensión $droop$. Tanto el control de tensión como el de frecuencia actúan para ajustar la referencia del control primario, incorporando dos señales, u_v y u_ω, en el control de caída de tensión, de acuerdo con la siguiente formulación:

$$\begin{aligned} \omega^* &= \omega_n - R_p P + u_\omega, \\ v_{od}^* &= v_n - R_q Q + u_v. \end{aligned} \tag{2.27}$$

En las siguientes secciones se detallan las estrategias para el cálculo de los controladores centralizados y distribuidos, cuyo desempeño se compara en escenarios relevantes de una microrred prototipo.

2.4 Controladores centralizados

2.4.1 Control tipo PI de Ebrahim

Este control propuesto por Ebrahim et al en [44] se basa en obtener las señales de comparación mediante controladores secundarios tipo PI, cuyas entradas son los errores en amplitud de voltaje y frecuencia. La Figura 2.7 muestra la estructura principal del control secundario. Las señales de control necesarias para restablecer los valores deseados de frecuencia angular y magnitud de tensión según [42] son:

$$u_\omega = k_{p\omega}\left(\omega_n - \omega_{PCC}\right) + k_{i\omega}\int\left(\omega_n - \omega_{PCC}\right)dt \tag{2.28}$$

$$u_v = k_{pv}\left(v_n - v_{PCC}\right) + k_{iv}\int\left(v_n - v_{PCC}\right)dt, \tag{2.29}$$

donde ω_n y ω_{PCC} son los valores de referencia y medidos de la frecuencia angular de la microrred en el punto de acople común PCC, y v_n y v_{PCC} son los valores de referencia y medidos de la amplitud de tensión de la microrred, respectivamente, mientras que $k_{p\omega}, k_{i\omega}, k_{pv}$ y k_{iv} son los coeficientes PI de los controladores secundarios. Es de resaltar que las señales de control sirven para compensar todas las unidades de generación de la microrred, ya que las referencias se forman del PCC.

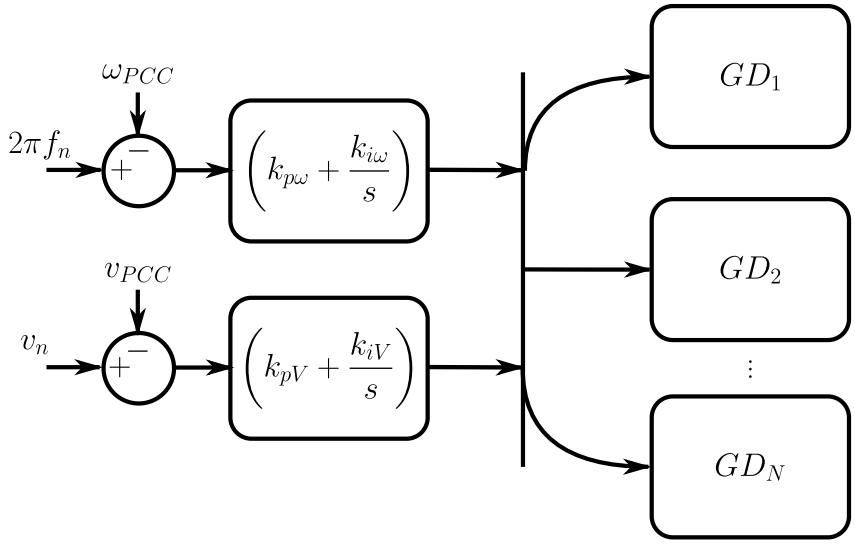

Figura 2.7: Estructura general control secundario de Ebrahim. Adaptado de [44]

2.4.2 Control MRAC

La arquitectura de un controlador MRAC se basa en la de un control por modelo de referencia adaptativo (MRAC, *Model Reference Adaptative Control*), el cual utiliza dos

redes neuronales: una red de controlador y una red de modelo de planta, como se muestra en la Figura 2.8.

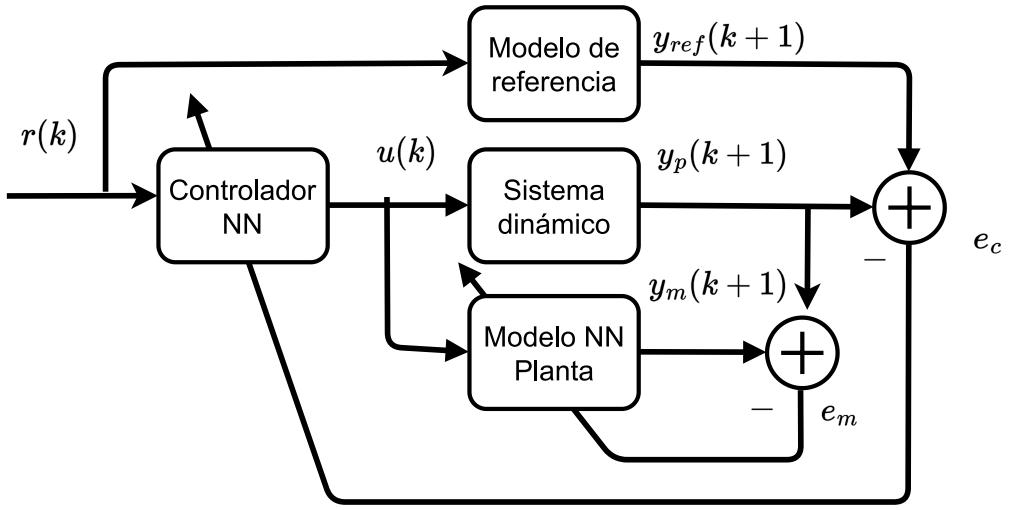

Figura 2.8: Diagrama general de un controlador MRAC

En esta estructura, el controlador de la red neuronal proporciona la señal de control adecuada $u(k)$ al sistema para mantener la salida $y_p(k+1)$ lo más cerca posible de la salida deseada $y_{ref}(k+1)$, especificada por la referencia $r(k)$. El error de seguimiento $e_c(k)$ entre la salida del modelo de referencia de la red neuronal y la salida del sistema se utilizan para ajustar los parámetros del controlador.

El modelo de referencia establece el desempeño requerido del sistema de lazo cerrado. Este debe elegirse cuidadosamente para que el sistema de bucle cerrado pueda alcanzar el rendimiento requerido. El controlador puede ser entrenado de forma on-line, como se muestra en la Figura 2.8, o de forma off-line. En el modo off-line (usado en este caso), se tiene una estructura neuronal como la mostrada en la Figura 2.9, con una red neuronal compuesta por cuatro capas que representan el sistema con su controlador actuando en lazo cerrado. La segunda red representa una aproximación al modelo de la planta, que en conjunto permiten ajustar el control para seguir al modelo de referencia.

Cabe destacar que para el control de la planta no se requiere toda la red completa, sino las capas correspondientes al controlador. Sin embargo, en este tipo de estructura no se cuenta con datos para entrenar únicamente las correspondientes al controlador de forma directa, por lo que se requiere una forma de entrenar la red completa de forma indirecta. Teniendo en cuenta esta problemática, se entrena el controlador mediante el sistema general controlado en lazo cerrado, con lo cual solo se requiere obtener datos de la planta a controlar y del modelo de referencia para el entrenamiento.

Por lo anterior, la forma de calibrar el controlador se basa en primer lugar en entrenar de forma independiente una red que emule las dinámicas de la microrred. Los pesos de esta

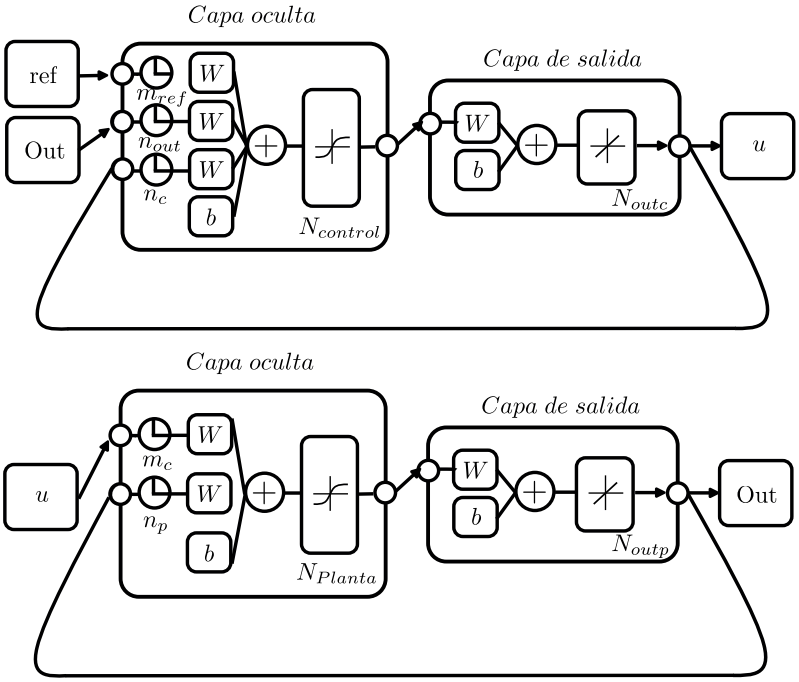

Figura 2.9: Esquema control neuronal tipo MRAC off-line

red se usarán en las dos últimas capas de la red, de forma que solo deban entrenarse los pesos de las dos primeras capas que corresponden al controlador.

2.4.2.1 Redes tipo NARX: Las redes constitutivas del controlador MRAC son tipo NARX, cuya estructura se puede observar en la Figura 2.9, que son redes dinámicas recurrentes formada por varias capas y con retroalimentación. Esta red se basa en un modelo autorregresivo utilizado para describir sistemas que tienen inercia. El valor predicho depende de n valores de salida anteriores y m valores de entrada anteriores. Como datos de entrada se utilizan las salidas de la propia red con sus respectivas entradas y las referencias deseadas [69].

La red NARX estándar es una red de dos capas de distribución inversa, con una capa oculta que utiliza una función de activación sigmoidal, mientras que se emplea una función de activación lineal para la capa de salida. En el caso del control MRAC de la Figura. 2.9, m_{ref} y m_c son los retrasos de las referencias deseadas y la señal de control, respectivamente, mientras que n_{out}, n_c y n_p son el número de retrasos de la señal de salida de la red neuronal, de la salida de las capas del controlador y de la salida de las capas que representan el sistema.

2.5 Controladores Distribuidos

Los controladores distribuidos son una alternativa a los controladores centralizados. En lugar de tener un solo controlador que supervisa todo el sistema, estos controladores se encuentran distribuidos por toda la microrred, cada uno controlando un elemento o subconjunto del sistema.

Los controladores distribuidos pueden o no tener, control de potencia reactiva (RPC). En el caso de aquellos con RPC, este puede ayudar a mejorar la calidad de la energía en la microrred. El RPC utiliza información de la tensión y la corriente en la microrred para calcular las acciones de control necesarias para mantener la tensión dentro de los límites aceptables. Esto es importante en microrredes que contienen cargas no lineales, que pueden causar fluctuaciones de tensión.

Las cargas no lineales pueden provocar un reparto impreciso de la potencia reactiva. Esto se debe a que consumen energía de forma irregular, lo que puede provocar diferentes caídas de tensión en las unidades de GD. Para compensar este efecto, los controladores con RCP añaden un término de corrección de tensión a 2.27. Este término ayuda a imponer un reparto de potencia reactiva preciso mediante la regulación de la referencia de tensión.

2.5.1 Sin control de potencia reactiva

2.5.1.1 Control de consenso tipo PI de Mengxuan: Para resolver los desafíos asociados al control convencional de tensión frente a perturbaciones en la entrada, se propone en [70] un controlador PI de consenso que prescinde del observador de tensión. Además, se fusiona el control de la tensión promedio con el control de potencia reactiva en un solo controlador, lo que simplifica significativamente la estructura global. Se desarrollan algoritmos de control similares para el control de frecuencia y potencia activa.

La integración del control de tensión y potencia reactiva permite la generación de una única señal de control para ajustar la referencia de tensión del bucle interno [42]. Por ende, la tensión de referencia para cada Generador Distribuido (GD) con la implementación del control de tensión secundaria puede ser obtenida de esta manera:

$$\begin{aligned} \dot{u}_{vi} = & \sum_{j \in N_i} a_q \left(\bar{Q}_j - \bar{Q}_i\right) - \\ & g_q \left(u_{vi} - \bar{Q}_i\right), \\ \dot{\zeta}_{vi} = & -\sum_{j \in N_i} b_q \left(\bar{Q}_j - \bar{Q}_j\right), \end{aligned} \tag{2.30}$$

donde $\bar{Q}_i = R_{q,i} Q_i$, siendo $R_{q,i}$ el coeficiente de $droop$ de tensión, mientras que N_i es el conjunto de GD que tienen comunicación con el GD i-ésimo, a_q, b_q y g_q son coeficientes de peso y ζ_{vi} es una variable adicional introducida por el algoritmo de consenso PI.

La Figura 2.10 presenta el diagrama del controlador de tensión de consenso PI, el cual fusiona una sección de consenso de potencia reactiva con una sección de recuperación de

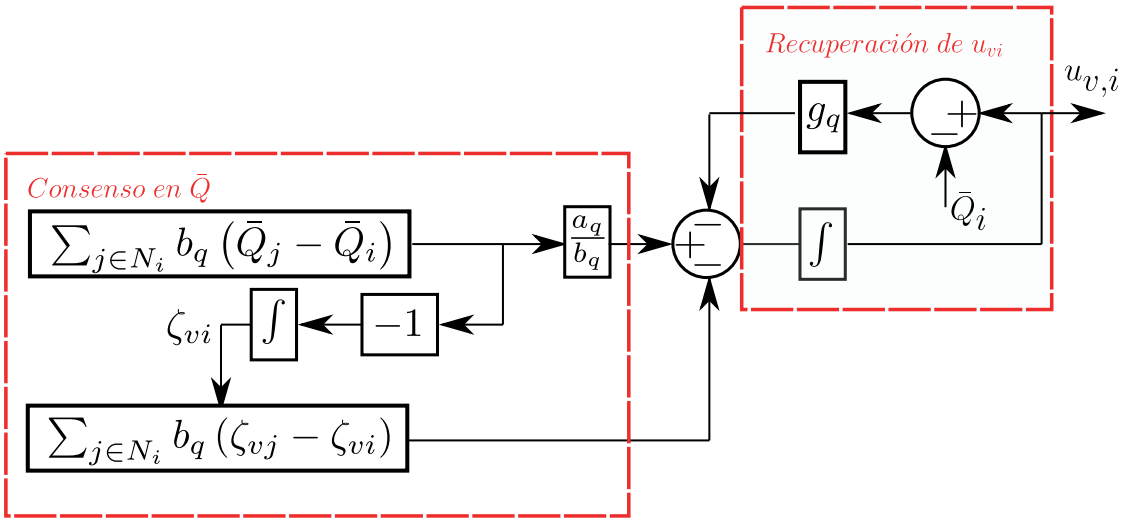

Figura 2.10: Estructura general control de voltaje de Mengxuan. Adaptado de [70]

tensión. Debido a la inclusión de variables adicionales, la sección de consenso de potencia efectivamente comprende un término proporcional y uno integral de $\bar{Q}_i$. Por lo tanto, el algoritmo ilustrado en la ecuación (2.30) se clasifica como un algoritmo de consenso PI.

Dado que la microrred de AC tiene una frecuencia de red unificada, el reparto proporcional de la potencia activa puede garantizarse independientemente de la existencia de la línea, pero siempre existe una desviación de la frecuencia nominal debido a las características del $droop$. Si bien el control distribuido basado en algoritmos de consenso puede proporcionar una compensación idéntica para cada GD con el fin de restablecer la frecuencia, normalmente se necesita un GD líder para obtener el valor de la frecuencia nominal [7]-[9]. En este caso se propone al igual que en [42], un control distribuido entre iguales, donde no se requiere un líder y la frecuencia nominal no interviene en el control secundario de la frecuencia.

Con el fin de restablecer la frecuencia sin alterar la proporción de distribución de potencia activa, es necesario que el término de compensación $u_{\omega i}$ para cada Generador Distribuido (GD) sea uniforme y cumpla con la condición $u_{\omega i} - R_{pi}P_i = 0$. Para alcanzar estos objetivos de control, el controlador de frecuencia basado en el consenso PI se deriva mediante:

$$\begin{aligned} \dot{u}_{\omega i} = & \sum_{j\in N_i} a_p\left(u_{\omega_j} - u_{\omega_i}\right) - \\ & g_p\left(u_{\omega i} - \bar{P}_i\right), \end{aligned} \tag{2.31}$$

$$\dot{\zeta}_{\omega i} = -\sum_{j\in N_i} b_p\left(\bar{u}_{\omega j} - u_{\omega i}\right),$$

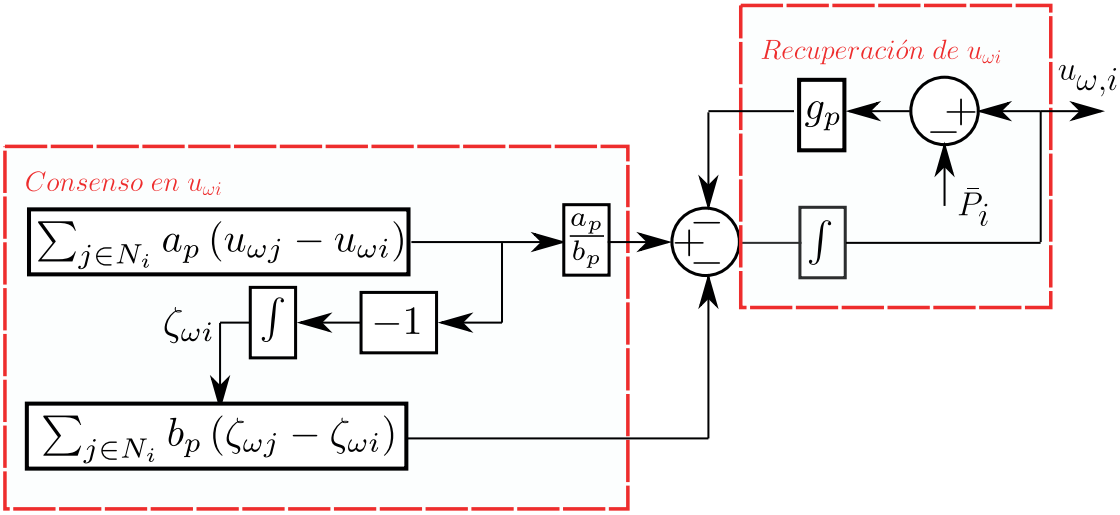

Figura 2.11: Estructura general control de frecuencia de Mengxuan. Adapatado de [70]

donde $\bar{P}_i = R_{pi}P_i$ y $\zeta_{\omega i}$ es una variable adicional introducida por el algoritmo de consenso PI.

En la Figura 2.11 se muestra el esquema del controlador de frecuencia de consenso PI, de donde se obtiene la señal de compensación secundaria $u_{\omega i}$.

2.5.2 Con control de potencia reactiva

2.5.2.1 Control de consenso tipo PI de Shaffie 2014: El control secundario, propuesto en [71], recoge de cada GD todas las medidas (frecuencia, amplitud de tensión y potencia reactiva), así como de las otras unidades GD a través del sistema de comunicación. Mediante una operación de promedio, produce la señal de control adecuada para enviarla al nivel primario, eliminando así los errores de estado estacionario.

En esta estrategia, para el control de frecuencia, cada GD mide el nivel de frecuencia en cada tiempo de muestreo, lo envía a los demás, promedia la frecuencia medida por los otros GD y, a continuación, restablece la frecuencia internamente como:

$$u_\omega = k_{p\omega}\left(\omega^* - \bar{\omega}\right) + k_{i\omega}\int\left(\omega^* - \bar{\omega}\right)dt,$$

siendo $k_{p\omega}$ y $k_{i\omega}$ los parámetros del controlador PI, ω^* es la referencia de frecuencia de la MG y $\bar{\omega}$ es la media de frecuencia para todas las unidades GD. El control de frecuencia completo se puede observar en Figura 2.12, destacándose que hay un único valor u_ω para todos los GD.

Para el caso del voltaje, puede utilizarse un enfoque similar al del control de frecuencia distribuido, en el que cada inversor mide su error de tensión e intenta compensar la desviación de tensión causada por el *droop* de voltaje. En este caso, el restablecimiento de la tensión se obtiene de la siguiente manera:

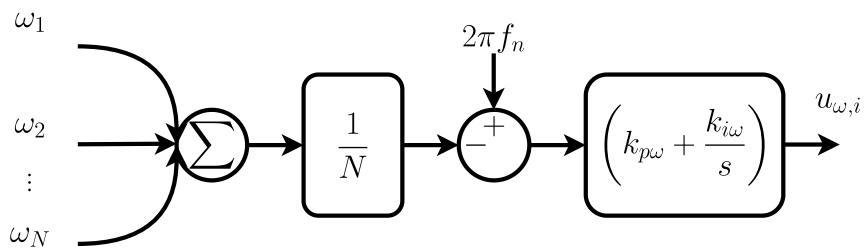

Figura 2.12: Estructura general control secundario de frecuencia de Shaffie 2014. Adaptado de [71]

$$u_v = k_{pV}\left(v_n - \bar{v}\right) + k_{iV}\int\left(v_n - \bar{v}\right)dt, \tag{2.32}$$

siendo k_{pV} y k_{iV} los parámetros del controlador PI, v_n es la referencia de voltaje de la MG y $\bar{v}$ es la media de frecuencia para todas las unidades GD.

Por otra parte, es bien sabido que en una microrred de baja R/X es difícil repartir con precisión la potencia reactiva, mismo efecto que se produce cuando se intenta repartir la potencia activa en microrredes de alta R/X. La razón es que, a diferencia de la frecuencia, la tensión no es común en toda la MG y la impedancia entre las unidades de GD y el punto común no es la misma. Por lo tanto, al utilizar la tensión como variable, es difícil controlar el flujo de potencia reactiva (o activa, en caso de MG de línea resistiva). Como resultado, la potencia reactiva no se controla con precisión si se utiliza el control de *droop*.

Una posible solución es implementar un control secundario para el reparto de potencia a nivel local, de modo que cada GD envíe la potencia medida Q (o P en microrredes de alto X/R) a las demás unidades para que se promedie. De este modo, como la información es común, todas ellas tendrán la misma referencia. Por lo tanto, el reparto de potencia reactiva por el control secundario puede expresarse como:

$$u_{Q,i} = k_{pQ}\left(\bar{Q} - Q_i\right) + k_{iQ}\int\left(\bar{Q} - Q_i\right)dt, \tag{2.33}$$

siendo k_{pQ} el término proporcional, k_{iQ} el término integral, Q_i la potencia reactiva del i-ésimo GD y $\bar{Q}$ el promedio de la potencia reactiva para todas las unidades que actúan como referencia de potencia reactiva. El control de voltaje completo se puede observar en la Figura 2.13. Normalmente la compensación de tensión u_v es la misma para todas las unidades, pero en el caso de la reactiva es individual.

Las señales de control secundario se intregran en el control $droop$, de manera que, en este caso, el control $droop$ queda de la siguiente manera:

$$v^*_{od,i} = v_n - R_{qi}Q_i + u_{v,i} + u_{Q,i}. \tag{2.34}$$

2.5.2.2 Control de consenso tipo PI de Shaffie 2016: Al igual que el anterior, el control secundario basado en [72] necesita todas las medidas (frecuencia, amplitud de tensión y potencia reactiva) de los GDs mediante el sistema de comunicación.

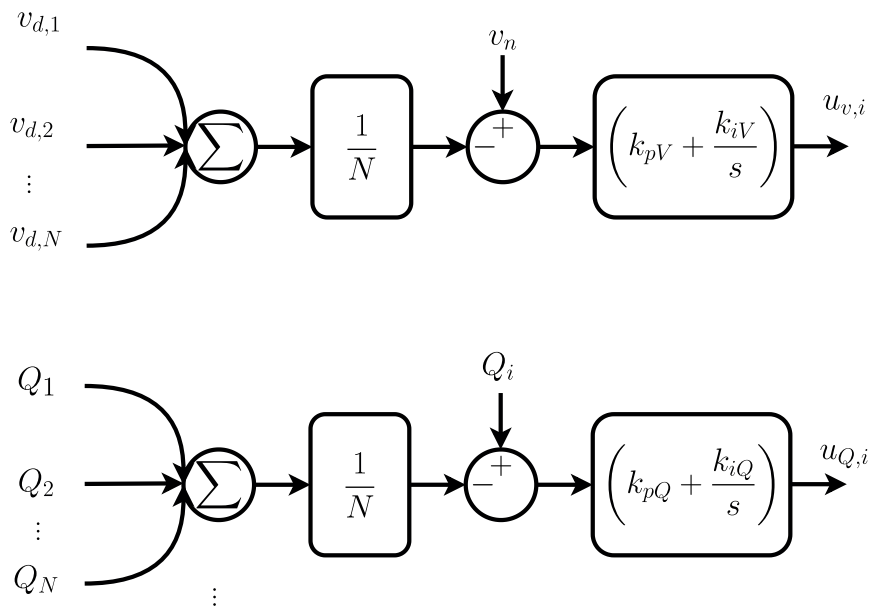

Figura 2.13: Estructura general control secundario de voltaje Shaffie 2014. Adaptado de [71]

Sin embargo, el regulador de tensión proporciona un término de corrección $u_{v,i}$ para aumentar la magnitud de la tensión en los terminales del inversor i-ésimo. Cada controlador tiene un estimador, mostrado en la Figura 2.14, que calcula la media de las magnitudes de tensión a través de la línea de distribución $\bar{v}_i$.

El módulo estimador del nodo i-ésimo proporciona la estimación de la magnitud de tensión media $\bar{v}_i$ y la intercambia con sus vecinos. Este cálculo se basa en el llamado protocolo de consenso dinámico:

$$\bar{v} = v_i + \int \sum_{j \in N_i} a_{ij} \left(\bar{v}_j - \bar{v}_i\right) dt, \tag{2.35}$$

donde $\bar{v}_j$ es la estimación de la magnitud de tensión media proporcionada por el módulo estimador en el nodo j-ésimo. En el protocolo de actualización, la tensión local v_i se introduce directamente en el proceso de estimación, lo que implica que cualquier variación de tensión en el nodo i-ésimo afecta inmediatamente a la estimación en ese nodo. La diferencia entre esta estimación y la magnitud de tensión nominal v_n se introduce en un controlador PI para para obtener el término de corrección de tensión u_v.

El rendimiento del controlador de *droop* de tensión se ve comprometido en presencia de las impedancias de la línea de distribución. El módulo regulador de potencia reactiva de cada inversor ajusta los coeficientes de estatismo según las condiciones de carga de la microrred. El regulador de potencia reactiva del nodo i-ésimo recibe las potencias reactivas normalizadas de todos sus vecinos, es decir, los términos $\hat{Q}_j$ de todos los nodos j-ésimos,

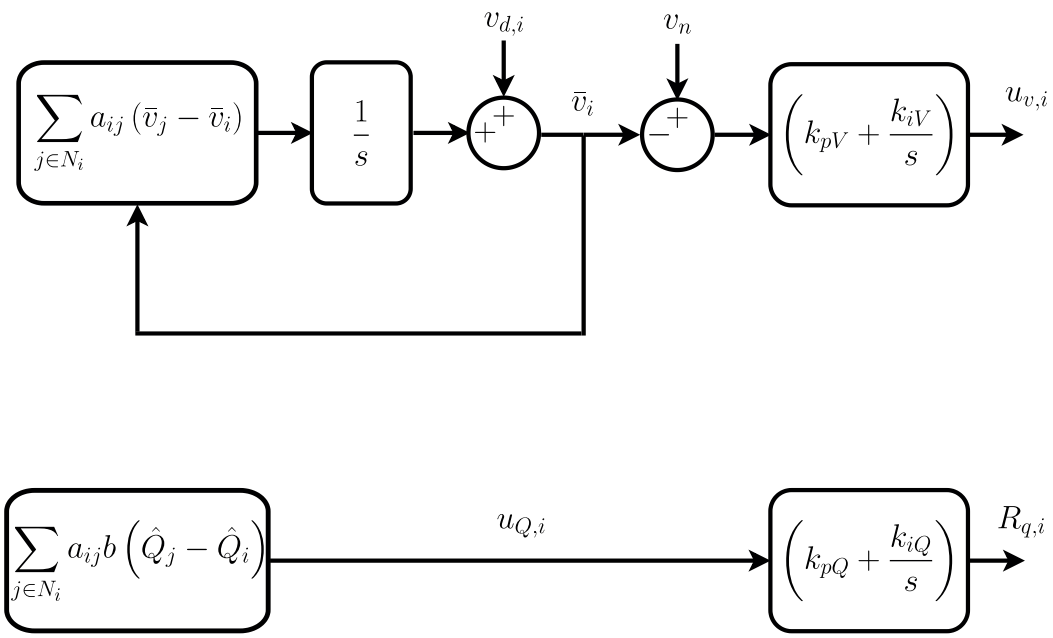

Figura 2.14: Estructura general control secundario de voltaje de Shaffie 2016. Adaptado de [72]

$j \in N_i$. A continuación, su potencia reactiva normalizada se compara con una media ponderada de las potencias de sus vecinos para encontrar el desajuste de carga u_{Qi}, dado por:

$$u_{Qi} = \sum_{j\in N_i} ba_{ij}\left(\hat{Q}_j - \hat{Q}_i\right), \tag{2.36}$$

donde a_{ij} son los pesos de comunicación, siendo $a_{ij} = 1$ si el nodo i-ésimo recibe información del nodo j-ésimo y 0 en caso contrario, mientras que b es la ganancia de acoplamiento entre los reguladores de tensión y potencia reactiva. Esto permite utilizar la red de comunicación del módulo regulador de tensión. Como se ve en la Figura 2.14, el desajuste de carga u_{Qi} se aplica en un controlador PI para generar el término de corrección de *droop* R_{qi}. Este término de corrección se utiliza para actualizar el coeficiente

$$R_{qi}(t) = R_{qi0} - u_{Qi}, \tag{2.37}$$

con R_{qi0} como la asignación inicial del valor de *droop* de voltaje. Esta operación ayuda a reducir el desajuste de carga entre inversores vecinos y, en última instancia, de toda la microrred.

En cuanto al control de frecuencia, los métodos convencionales de sincronización utilizan mecanismos de retroalimentación que requieren la medición de frecuencias. Esto puede provocar una respuesta lenta y una desviación de frecuencia relativamente grande en

presencia de perturbaciones. Por lo tanto, se usa un controlador que no requiere la medición de la frecuencia, lo que conduce a una desviación de frecuencia menor.

El controlador de la frecuencia proporciona una media estimada de la potencia activa normalizada $\hat{P}_i$. De forma similar al proceso de estimación de la tensión, esta evaluación se realiza mediante un protocolo de consenso dinámico, como se muestra en la Figura 2.15. Este valor medio se utiliza como señal global que se añade al *droop* de frecuencia. En consecuencia, el controlador del nodo i-ésimo actualiza dinámicamente su valor medio basándose en

$$\bar{P} = \hat{P}_i + \int \sum_{j \in N_i} c a_{ij} \left(\bar{P}_j - \bar{P}_i \right) dt, \tag{2.38}$$

donde la ganancia de acoplamiento c es un parámetro de diseño y $\bar{P} = u_\omega$ es la potencia activa media normalizada proporcionada por el estimador en el nodo j-ésimo vinculado con el nodo i-ésimo. Como se ve en (2.38), el protocolo de actualización utiliza la potencia activa normalizada local $\hat{P}_i$ para tener en cuenta la variación de la potencia activa en el proceso de estimación.

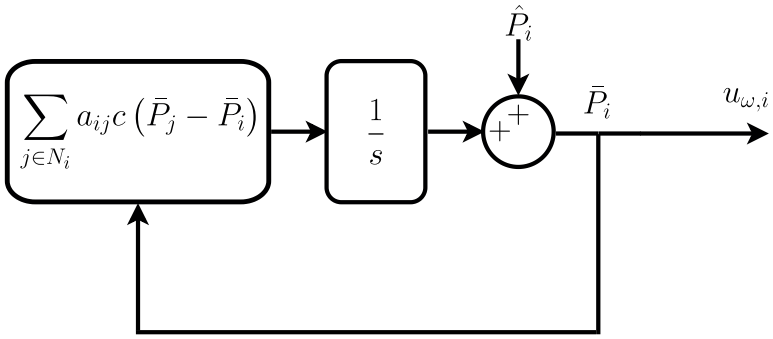

Figura 2.15: Estructura general control secundario de frecuencia de Shaffie 2016. Adaptado de [72]

2.5.2.3 Control Cooperativo de Xiangyu: Basado en la teoría de grafos, el control cooperativo distribuido presentado en [52] se implementa a través de una red de comunicación dispersa modelada por un digrafo. El estado de información escalar x_i se asigna al nodo de comunicación i-ésimo. Cada nodo requiere su propia información y la de su vecino j $(j \in N_i)$ en el digrafo para actualizar su estado x_i.

La regla de actualización se basa en el algoritmo de consenso continuo para el problema de sincronización de reguladores y el de sincronización de seguimiento. El diseño del controlador es una combinación de un problema de seguimiento y regulación, y está dado por:

$$\begin{aligned}\dot{u_\omega} = &- c_{\omega i} \sum_{j \in N_i} a_{ij} \left[a_{ij} \left(\omega_i - \omega_j \right) + g_i \left(\omega_i - \omega^* \right) \right] \\ &- c_{Pi} \sum_{j \in N_i} a_{ij} \left(R_{pi} P_i - R_{pi} P_i \right),\end{aligned} \tag{2.39}$$

donde $c_{\omega i}$ y c_{Pi} son ganancias de control positivas.

En el caso del control de voltaje, la señal de control u_v se selecciona de forma que el voltaje v_{od} de cada unidad de GD converja al mismo valor de referencia v_n, que es un problema de sincronización de seguimiento dado por:

$$\dot{u_v} = - c_{vi} \sum_{j \in N_i} a_{ij} \left[\left(v_i - v_j \right) + g_i \left(v_i - v_{ref} \right) \right], \tag{2.40}$$

donde c_{vi} es una ganancia de control positiva y $\sum_{j \in N_i} a_{ij} \left[\left(v_{odi} - v_n \right) + g_i \left(v_{odi} - v_n \right) \right]$ es el error de seguimiento del vecino local de v_i que permite regular la tensión. El valor de referencia v_{ref} se selecciona mediante un controlador PI de forma que v_{PCC} recupere su valor nominal de referencia v_n con error cero, es decir:

$$\begin{aligned}v_{ref} = v_n &+ k_p \left(v_n - v_{PCC} \right) \\ &+ k_i \int \left(v_n - v_{PCC} \right) dt,\end{aligned} \tag{2.41}$$

donde k_p y k_i son las ganancias del controlador PI.

Por último, se incluye un control de reparto de potencia reactiva para una distribución más precisa de las cargas entre los GDs. Igual que en la estrategia anterior, se añade el término de corrección de tensión u_Q en el *droop* de voltaje para imponer un mejor reparto de potencia reactiva.

El término Q_i se selecciona de forma que el término $R_{qi} Q_i$ del control *droop* de cada unidad de GD converja a un valor común, que es un problema de sincronización del regulador dado por:

$$\dot{u}_Q = c_{Qi} \sum_{j \in N_i} a_{ij} \left(R_{qi} Q_i - R_{qj} Q_j \right), \tag{2.42}$$

donde c_{Qi} es una ganancia de control positiva y $\sum_{j \in N_i} a_{ij} \left(R_{qi} Q_i - R_{qj} Q_j \right)$ es el error de seguimiento de los vecinos de $R_{qi} Q_i$. Esto permite una distribución precisa de la potencia reactiva.

2.6 Sintonización y entrenamiento de controladores

Como se ha abordado en secciones previas, todos los controladores presentados cuentan con una serie de parámetros esenciales para su correcto funcionamiento. Estos parámetros ejercen una significativa influencia tanto en su rendimiento como en la estabilidad inherente

al sistema, de ahí que resulte fundamental llevar a cabo una calibración apropiada de los mismos.

Existen diversas metodologías disponibles para calibrar los parámetros mencionados, como la técnica de ubicación de polos y otras existentes. En este contexto, se ha decidido emplear técnicas heurísticas para calibrar todos los controladores, a excepción del MRAC. Dado que el MRAC es un controlador neuronal, se requiere otro enfoque para la elección de hiperpárametros.

2.6.1 Entrenamiento del control MRAC

El primer paso para poder entrenar las capas de la red neuronal correspondientes a la planta es escoger las variables de entrada y salida que se emplearán para representar las dinámicas de una MG. Dado el enfoque de este trabajo, se usan las señales más importantes del control secundario, las cuales son la transformada de Park del voltaje en su variable d y la frecuencia. Las señales se toman con un tiempo de muestreo de 0.5 ms en el punto de acople común PCC.

2.6.1.1 Obtención del dataset: Para obtener estos datos de las dinámicas de la MG, se requiere generar señales dinámicas que actúen como señales de entrada. Para producir estas señales se realizan pruebas que permitan encontrar los máximos, mínimos y su duración, de tal manera que representen de forma idónea las dinámicas de la planta. Mediante pruebas realizadas se encontró que los mejores intervalos para la MG escogida son $u_v \in [6\ 20]$ en amplitud para la señal de voltaje y $u_f \in [1.1\ 2]$ para la señal de frecuencia con tiempos variables de entre $[2.5,\ 50]$ ms. Sin embargo, es necesario recalcar que la MG es bastante sensible ante los cambios abruptos, por lo que se necesitó tratar la señal de entrada mediante un filtro de media móvil.

En cuanto a los datos del modelo de referencia, se crearon señales de entrada $v_n \in [308\ 315]$ para la señal de voltaje y $f_n \in [59.8\ 60.1]$ para la señal de frecuencia con tiempos variables de entre $[2.5\ 50]$ ms. Para ello se escogió un modelo dinámico de referecia lineal de segundo orden, que puede representarse mediante

$$G(s) = \frac{\omega_{natural}^2}{s^2 + 2\zeta\omega_{natural}s + \omega_{natural}^2}, \tag{2.43}$$

el cual tiene un factor de amortiguamiento (ζ) igual a 0.9 y una frecuencia natural ($\omega_{natural}$) de aproximadamente 11.11. Lo anterior brinda un sistema de segundo orden subamortiguado, sin error de estado estacionario y con un tiempo de establecimiento de 0.1 s.

La Figura 2.16 muestra las señales de entrada generadas que se utilizan en la microrred y en la planta de referencia con las que se obtienen las señales de salida necesarias para el entrenamiento del controlador.

2.6.1.2 Preprocesamiento de datos: Una vez obtenidas las señales de entrada y salida, se procede a su acondicionamiento. Para ello, se normalizan con media cero y desviación

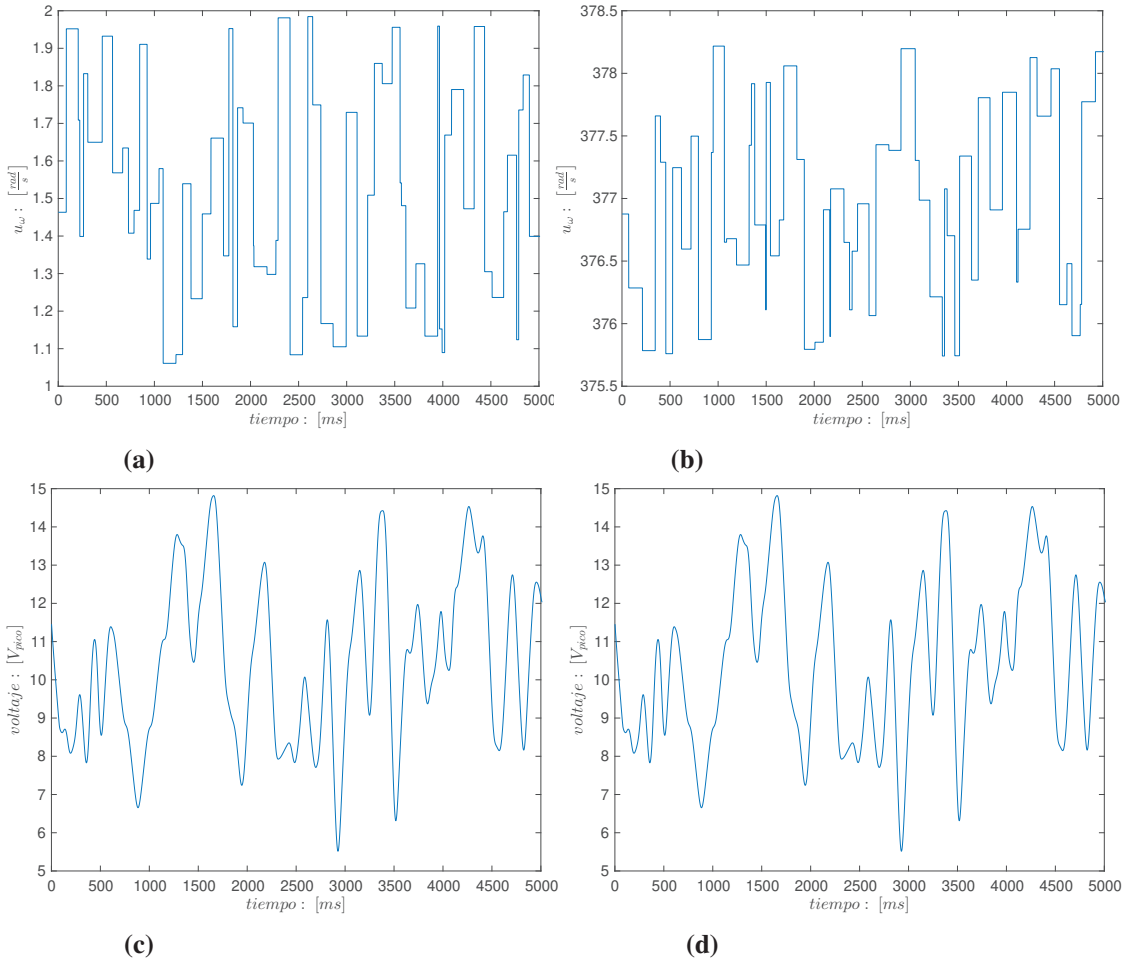

Figura 2.16: Señales de entrada generada: (a) u_ω MG, (b) u_ω planta de referencia, (c) u_v MG, (d) u_v planta de referencia

estándar igual a 1, y se escalan a valores en el intervalo $[-1, 1]$ [73]. La Figura 2.17 muestra las señales originales y procesadas, las cuales están escaladas, normalizadas y suavizadas.

2.6.1.3 Cálculo del grado de orden del modelo de red NNARX: La determinación del orden del modelo (retrasos de entradas y salidas de la red que emula la planta) se lleva a cabo mediante el método de números de Lipschitz [74], el cuál es un método determinista que hace uso de la información geométrica de los datos de entrada-salida. El método funciona para las estructuras de modelos NARX y sistemas lineales o no lineales.

El método se basa en la propiedad de continuidad de las funciones que representan los modelos de entrada-salida y no depende del uso de ningún método de aproximación o estructura de modelo particular. Aunque el método se desarrolló para su uso con sistemas deterministas, también es válido para sistemas con un bajo nivel de ruido de medición.

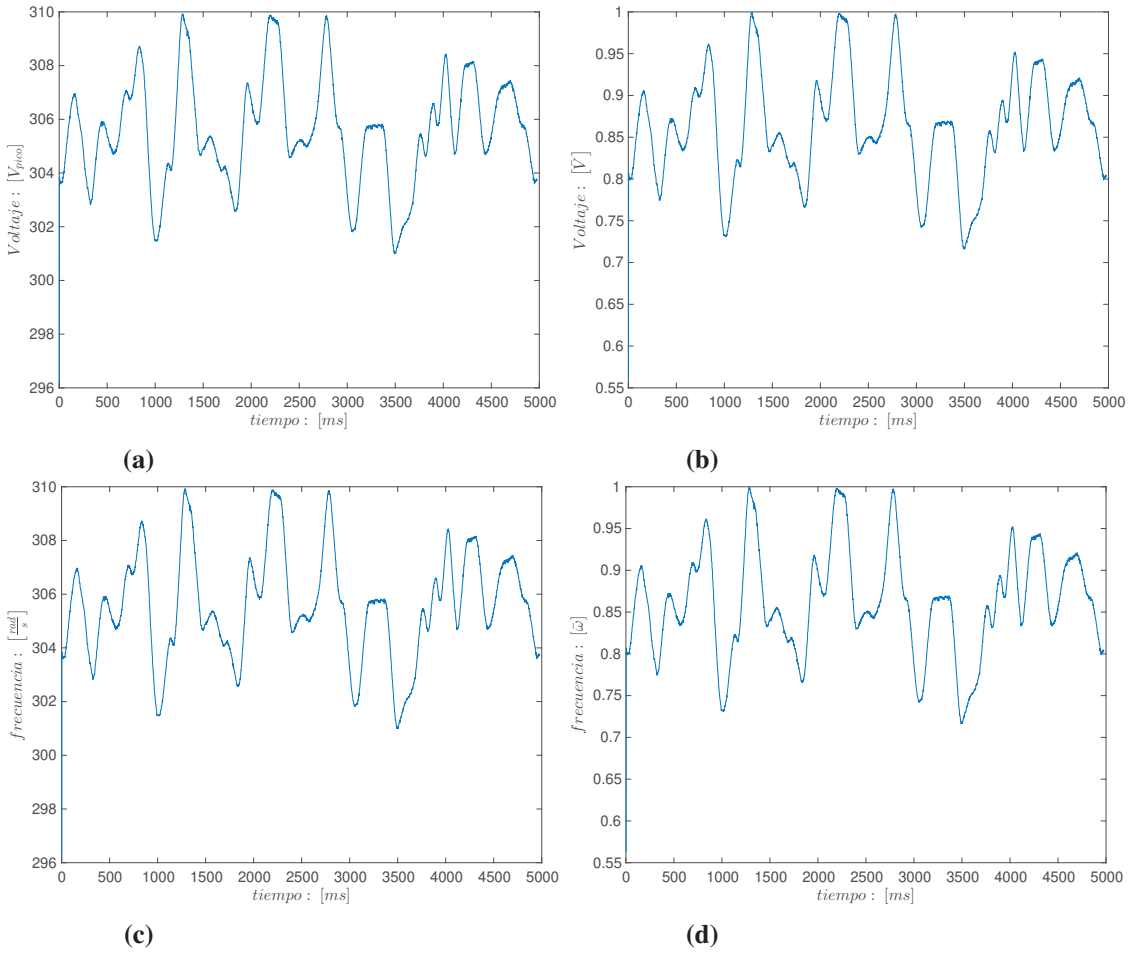

Figura 2.17: Curvas de respuesta obtenidas: (a) v_{PCC} original, (b) v_{PCC} preprocesada, (c) ω_{PCC} original, (d) ω_{PCC} preprocesada

La metodología considera una formulación general de entrada-salida dada por $y = F(x)$, donde $F[*]$ es una función continua y suave, suponiendo que las derivadas parciales de la función con respecto a sus argumentos están acotadas. Es de notar que la extensión a los sistemas de entradas y salidas múltiples es sencilla. A partir de pares de entrada-salida $\{x(i), y(i)\}$ de datos, se obtiene el cociente Lipschitz,

$$q(i,j)^{(s)} = \frac{\|Y(i) - Y(j)\|}{\|X(i) - X(j)\|} \; para \; i \neq \; j, j = 1, 2, \ldots, N \tag{2.44}$$

donde N es el número de muestras del conjunto de datos, X es la matriz de señales de entrada, Y es la matriz de señales de salida y $s = m + n$ es el orden total del modelo, siendo m la cantidad de salidas previas utilizadas y n el número de entradas previas. El cociente de Lipschitz es una relación entre la diferencia absoluta entre las señales de salida

y la distancia entre las señales de entrada. Si la función $F[*]$ es continua, la condición Lipschitz establece que el cociente debe estar acotado entre cero y un valor finito L para cualquier par de entrada-salida. Además, se tiene que los cocientes de Lipschitz se vuelven relativamente pequeños y estables a medida que aumentan los órdenes del modelo. Con base en lo anterior, es posible el uso de estos coeficientes para determinar el orden óptimo del modelo (el número de variables en el vector de entrada $x(i)$) directamente a partir de los datos de entrada-salida. Para este fin se usa un índice, denominado número de Lipschitz $L_Q(s)$, que permite identificar los órdenes óptimos de los modelos. El número $L_Q(s)$ es la media geométrica ponderada de los mayores cocientes de Lipschitz calculados a partir de del conjunto de pares de entrada-salida dado por

$$L_Q(s) = \left[\sqrt{m} \prod_{k=1}^{r} q^s(k) \right]^{\frac{1}{r}}, \tag{2.45}$$

donde r es un número positivo (que se recomienda que sea aproximadamente $0,01N$), y $q^{(s)}(k)$ es el k-ésimo mayor cociente de Lipschitz entre todos los $q(i,j)^{(s)}$. El número de Lipschitz se controla en función de s para determinar el orden total óptimo $p = m_{óptimo} + n_{óptimo}$. En concreto, p es el orden total óptimo si $L_q(p-1) \gg L_q(p)$ y $L_q(p) \sim L_q(p+1)$. Además, se espera que $L_q(p-2) \gg L_q(p-1)$. El orden total del modelo p se elige como el valor más pequeño de s, para el cual se cumple que ya no hay cambios significativos en el número de Lipschitz.

Para el resto de hiperparámetros, tales como el número de neuronas de las capas, se varía el parámetro a calibrar, dejando los demás fijos, de forma que se escoge aquel donde ya no se evidencien cambios significativos en el desempeño del controlador.

2.6.1.4 Modelo resultante: Con el fin de evaluar las capacidades del controlador propuesto, se llevaron a cabo dos entrenamientos utilizando esta técnica. El primero de estos entrenamientos se enfocó en desarrollar dos controladores de tipo SISO (Single Input Single Output), uno diseñado para el control de voltaje y otro para el control de frecuencia. En cuanto al segundo entrenamiento, se configuró un sistema MIMO (Multiple Input Multiple Output), de manera que un solo controlador pudiera recibir las señales de entrada y generar las señales de control correspondientes para múltiples salidas.

Finalmente, una vez entrenados, se toman únicamente los pesos de las dos primeras capas que corresponden al controlador, dejando la red neuronal con solo dos capas.

2.6.2 Método heurístico

En este caso, siguiendo las recomendaciones de [29], se establece el siguiente problema de minimización:

$$\min_{\bar{w}} \quad 0.6ITAE_f + 0.4ITAE_v \tag{2.46}$$

con

$$ITAE_f = \int_0^\tau t|e_f(t)|\,dt = \int_0^\tau t|\bar{f} - 1|\,dt \tag{2.47}$$

$$ITAE_v = \int_0^\tau t|e_v(t)|\,dt = \int_0^\tau t|\bar{v} - 1|\,dt \tag{2.48}$$

Donde $\bar{f}$ y $\bar{v}$ representan la frecuencia y el voltaje normalizados, respectivamente. El vector $\bar{w}$ agrupa los parámetros que se necesitan ajustar en el controlador.

Una vez establecida la función de costo, se procede a determinar los mencionados parámetros de los controladores, los cuales serán obtenidos mediante el método heurístico de Optimización por Enjambre de Partículas y Evaluación Diferencial (DEPSO).

2.6.3 Particle Swarm Optimization and Differential Evaluation (DEPSO)

A medida que las iteraciones avanzan en el algoritmo PSO, la diversidad de partículas disminuye significativamente, lo que incrementa la posibilidad de quedar atrapado en óptimos locales del espacio de soluciones. Por otro lado, aunque el algoritmo DE explora eficazmente estos óptimos locales mediante información diferencial, su calidad de búsqueda para encontrar óptimos globales se deteriora. La técnica DEPSO aborda este desafío combinando el operador DE con el algoritmo PSO, lo que enriquece la diversidad de la técnica de enjambre de partículas [24]. Varios estudios en la literatura han destacado aplicaciones en entrenamiento, agrupamiento y optimización, demostrando que DEPSO supera tanto a PSO como a DE en términos de calidad de solución y velocidad de convergencia. En DEPSO, la función del algoritmo DE consiste en explorar el espacio de búsqueda de manera estratégica para evitar que los individuos queden atrapados en óptimos locales. Por consiguiente, en cada iteración impar se emplea el algoritmo PSO, mientras que en las iteraciones pares se implementa el operador de mutación DE.

En esencia, el algoritmo opera mediante un enfoque convencional de enjambre de partículas durante las iteraciones pares, mientras que en las iteraciones impares, se elige un conjunto específico de partículas que serán sometidas a mutación y comparación con las partículas originales. Entre estas, se retienen las de mejor desempeño. La Figura 2.18 muestra un diagrama de flujo del proceso de implementación del algoritmo DEPSO donde J representa su función de *fitness*.

Con el propósito de ilustrar el proceso completo de calibración mediante el enfoque heurístico, se utilizará como ejemplo la calibración del control centralizado de Ebrahim. Como se mencionó anteriormente, este controlador consta de dos controladores PI, cada uno con dos parámetros a calibrar: $k_{p\omega}, k_{i\omega}, k_{pv}$ y k_{iv}. Por lo tanto, las partículas generadas serán vectores de 4 dimensiones, inicializados con valores aleatorios en el rango de cero a $[50\ 300\ 50\ 300]$.

Una vez que la población inicial ha sido creada, se procede a evaluar estos valores en un modelo matemático de la MG que incluye las señales de control secundario durante un período de un segundo. Los resultados de tensión y frecuencia obtenidos se promedian y luego se normalizan para calcular la aptitud (fitness). Estos resultados procesados se asignan a las partículas correspondientes y el proceso se repite de manera iterativa utilizando el

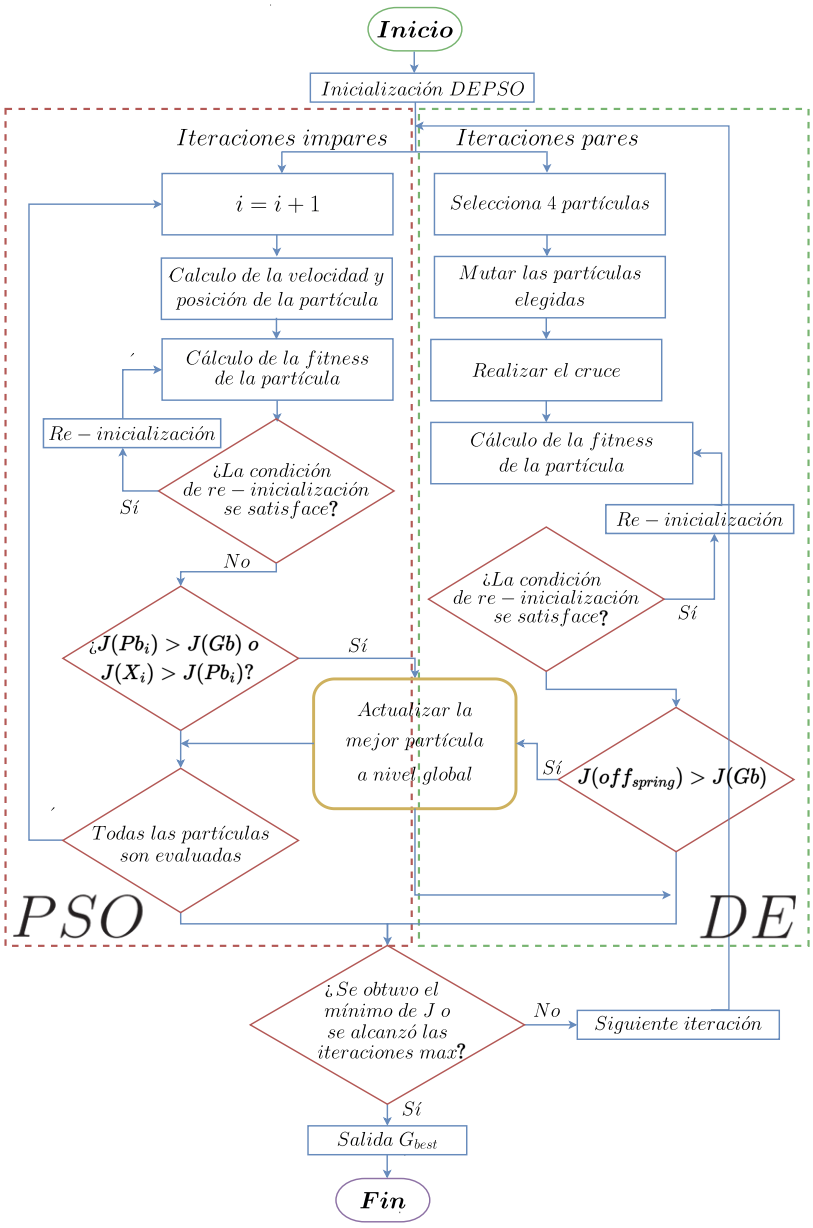

Figura 2.18: Diagrama algoritmo DEPSO, modificado de [24]

.

algoritmo de optimización previamente mencionado hasta alcanzar un número predefinido de iteraciones.

El mismo procedimiento se aplica a los demás controladores, que incluyen el de Mengxuan, el cual cuenta con parámetros a ajustar como $g_q,\ g_p,\ b_q,\ b_p,\ a_q$ y a_p; el controlador de Shaffie 2014, que involucra $k_{p\omega},\ k_{i\omega},\ k_{pV},\ k_{iV},\ k_{pQ}$ y k_{iQ}, y el controlador de Shaffie

2016, que requiere calibrar $b,\ c,\ k_pV,\ k_{iV},\ k_{pQ}$ y k_{iQ}. Un resumen de los parámetros calibrados con DPSO se muestran en la Tabla. 2.1.

Tabla 2.1: Carácterísticas de los controladores

Tipo	Controlador	Variables	Parámetros
Centralizados	Ebrahim	V y ω	$k_{p\omega}$, $k_{i\omega}$, k_{pv} y k_{iv}
	MRAC	V y ω	hiperparámetros
Distribuidos	Mengxuan	V y ω	b_p, b_q, a_p, a_q, g_p y g_q
	Shaffie$_{2014}$	V, ω y Q	$k_{p\omega}$, $k_{i\omega}$, k_{pV}, k_{iV}, k_{pQ} y k_{iQ}
	Shaffie$_{2016}$	V, ω y Q	b, k_{pV}, k_{iV}, k_{pQ} y k_{iQ}
	Xiangyu	V, ω y Q	c_w, c_P, c_v, k_p, k_i y c_Q

2.7 Resultados y discusión

2.7.1 Microrred de prueba

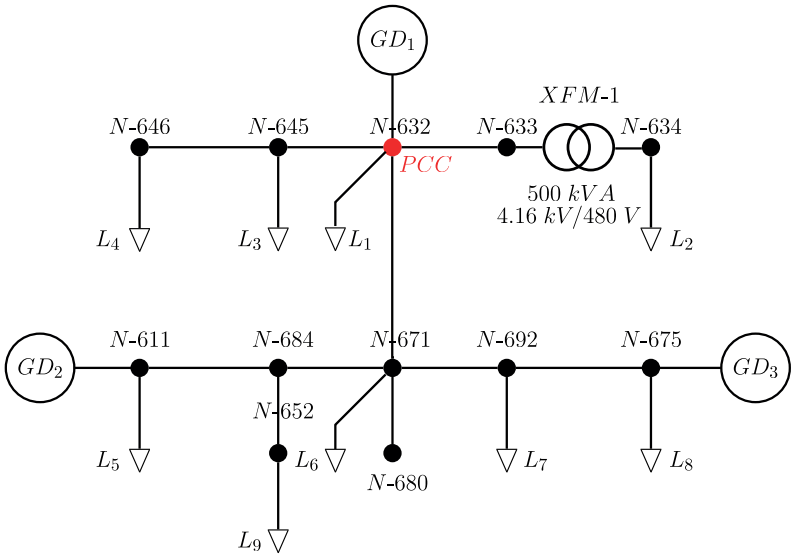

Figura 2.19: Diagrama de la red de prueba elegida

Para realizar el análisis de desempeño de los diferentes controles, se escogió la red IEEE de 13 nodos [75], a la cual se le realizan las siguiente modificaciones: Primero, se reemplaza la red externa por el generador distribuido GD_1; Segundo, a partir del estudio realizado en [76] se adicionan dos generadores distribuidos (GD_2 y GD_3), para finalmente trabajar con un sistema balanceado. La microrred propuesta se muestra en la Figura 2.19.

El modelo, consta de tres unidades de GD con cargas individuales y líneas de transmisión. Los parámetros de los GD implementados figuran en Tabla. 2.2.

Tabla 2.2: Parámetros de las GDs

	GD$_1$ & GD$_3$		**GD$_2$**	
Modelo	$R_{p1,3}$	$2.51e-7$	R_{p2}	$2.25e-7$
	$R_{q1,3}$	$2.72e-6$	R_{q2}	$2.51e-6$
	R_f	$100\ m\Omega$	L_f	$1.50\ mH$
	R_c	$30\ \Omega$	L_c	$0.34\ mH$
	C	$1.3\ F$		
	Voltaje		**Frecuencia**	
Referencia	v_n	$3396.6\ V_{pico}$	f_n	$60\ Hz$

Para validar los controladores implementados, se somete el sistema propuesto (ver Figura 2.19) a condiciones transitorias, como variaciones abruptas en la demanda energética de las cargas, fallos en las fuentes de energía y la integración de generadores distribuidos. Además, se lleva a cabo un análisis exhaustivo del rendimiento de los controladores secundarios en la microrred de prueba utilizando Simulink y la plataforma de simulación en tiempo real OP4510.

2.7.2 Simulación en tiempo real

OPAL-RT es una empresa que se dedica al desarrollo de equipos basados en PC y FPGA, así como equipos de pruebas SIL (*Software in the Loop*) y HIL (*Hardware in the Loop*). Algunas de las aplicaciones principales para estos sistemas son la simulación de redes eléctricas y de equipos basados en electrónica de potencia [36]. En este trabajo se usa el equipo de simulación en tiempo real OP4510, con el fin de analizar el comportamiento de los controladores secundarios en el entorno SIL. Para información detallada sobre el funcionamiento y configuración de la plataforma, se recomienda revisar la guía de usuario [37].

La simulación en la plataforma de tiempo real se realiza por medio de RT-LAB. Este entorno es el encargado de la compilación, carga y simulación de los modelos en el equipo OP4510. La versión de RT-LAB usada es la v2022.1.0.405, la cual es compatible con la versión de Matlab 2021b. Una vez se tiene instalada la versión de Matlab, es necesario instalar dos extensiones en Matlab: RT-LAB y RTEVENTS.

Luego de instalados los programas y paquetes necesarios para la simulación, se procede a cargar el modelo en OPAL-RT. El modelo debe ser dividido en dos subsistemas interconectados: un primer subsistema, cuyo nombre debe empezar con SM, y otro cuyo nombre empiece por SC, tal como se muestra en la Figura 2.20.

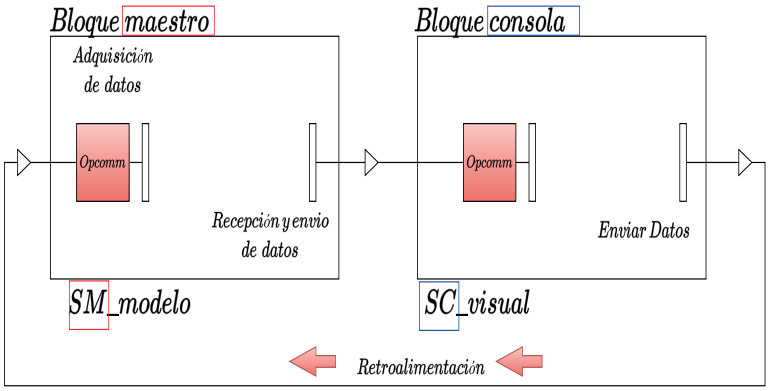

Figura 2.20: Estructura Maestro- Consola del archivo en Simulink en el entorno OPAL-RT

Como se puede apreciar, en el subsistema SM (*System Master*) se incluyen todos los bloques que intervengan en el cálculo dentro del modelo. Por otra parte, en el subsistema SC (*System Console*) deben incorporarse todos los bloques que actúen como interfaz hombre-maquina, incluyendo las variables cuyo valor se modifique a lo largo de la simulación y aquellas cuyo valor se quiera monitorizar en tiempo real.

Además de dividir el modelo, es necesario introducir una serie de bloques para el correcto funcionamiento de la simulación en tiempo real. Por fuera de los bloques SM y SC se deben incluir los bloques *powergui*, encargados de facilitar la simulación de los bloques de las biblioteca *Simscape, Electrical and Specialized Power Systems* y *Model Initialization*, por medio del cual se inicializa los parámetros del sistema. Otro de los bloques que deben incorporarse en el modelo es el denominado *OpComm*. Este bloque se encarga de gestionar la comunicación entre los distintos subsistemas. Por lo tanto, es imprescindible incluir uno en SM y otro en SC.

Es relevante mencionar que las simulaciones de Simulink se realizaron a $5\ \mu s$ mientras las simulaciones en RT-LAB se implementaron a $50\ \mu s$. Estos tiempos de muestreo fueron elegidos debido a las limitaciones técnicas de la plataforma OP4510. Asimismo, el controlador primario presenta limitaciones que no permiten observar las diferencias existentes en los controladores secundarios a un tiempo de muestreo de $50\ \mu s$.

De igual forma, es importante mencionar que se muestran únicamente los resultados obtenidos en la simulación de Simulink a $50\ \mu s$ puesto que, como se puede observar en la Tabla 2.3, no se encontraron diferencias notables entre las soluciones normales y las conseguidas en las simulaciones en RT-LAB, obteniendo correlaciones entre ellas de más de $98\ \%$. Se destaca que las señales de respuesta comparadas se obtuvieron en las mismas condiciones con un tiempo de muestreo $50\ \mu s$.

2.7.3 Escenarios de prueba y resultados en Simulink

Para el sistema representado en la Figura 2.19, se estableció un escenario operativo que abarca cinco condiciones distintas de funcionamiento: i) El sistema opera exclusivamente

Tabla 2.3: Métricas de correlación RT-LAB-Simulink

	Tensión [%]	**Frecuencia** [%]	**Potencia** [%]
Ebrahim	99.62	98.70	99.14
Megxuan	99.62	99.84	99.15
Shaffie$_{2014}$	99.63	99.87	99.65
Shaffie$_{2016}$	99.34	99.15	99.45
Xiangyu	99.62	99.83	99.27
MRAC$_{\text{MIMO}}$	99.64	99.81	99.62
MRAC$_{\text{SISO}}$	99.53	99.64	99.76

con el controlador primario activo, ii) a los 0.5 segundos se activa el controlador secundario, iii) al segundo 1, con el controlador secundario operando, se duplica la carga del nodo tres, iv) a los 1.5 segundos, se reduce a la mitad la carga del nodo 3, v) finalmente, al segundo 2 se desconecta el GD_3 del sistema y se vuelve a conectar en el segundo 2.5.

Los resultados de la simulación respecto a la magnitud de voltaje se presentan en la Figura 2.21. Durante la primera etapa (0-$0.5\,s$), se observa que en todos los generadores distribuidos, la desviación en la tensión con solo el control primario es mínima, siendo inferior a $0.0001\ p.u$ según la calibración dada. En la segunda etapa (0.5-$1\,s$), al existir una desviación tan reducida en la tensión, el control secundario tiende a amplificar esta discrepancia en todos los controladores, con excepción de los controladores Megxuan, Xiangyu y el controlador MRAC SISO.

Además, se aprecia en la Figura 2.21 que se evidencian diferencias significativas en los resultados obtenidos en cada uno de los generadores. Estas disparidades se originan debido a las variaciones en las inductancias provocadas por la inclusión de los generadores distribuidos en diferentes nodos de la microrred, así como por las discrepancias en sus constantes de droop. Esto conlleva a que los controladores centralizados, como el Ebrahim, o los controladores que dependen del promedio generado para la señal de control, como el controlador Shaffie 2016, difieran en sus dinámicas y magnitudes de estado estacionario. Respecto al promedio de tensión en los nodos, se observa que este es considerablemente inferior al voltaje de los nodos donde se incluyeron los generadores. Esto se debe a que la magnitud de tensión decrece a medida que la energía transmitida se aleja de sus fuentes de generación, lo que implica que los nodos más distantes tendrán una tensión menor que incidirá en el promedio global.

En cuanto al desempeño, se nota que todos los nodos presentan un error de menos de $0.001\ p.u$, lo que resulta en una desviación de tensión de menos de 4 voltios respecto al valor nominal deseado. En las Figuras 2.21a, 2.21b y 2.21c, se aprecia que el controlador con el peor rendimiento varía al analizar cada nodo con generación; por ejemplo, para el GD_1, el controlador menos eficaz es el Ebrahim, pero no sucede lo mismo para el GD_2 y GD_3, donde el controlador menos efectivo es el Shaffie 2014. En cuanto a los mejores controladores, no

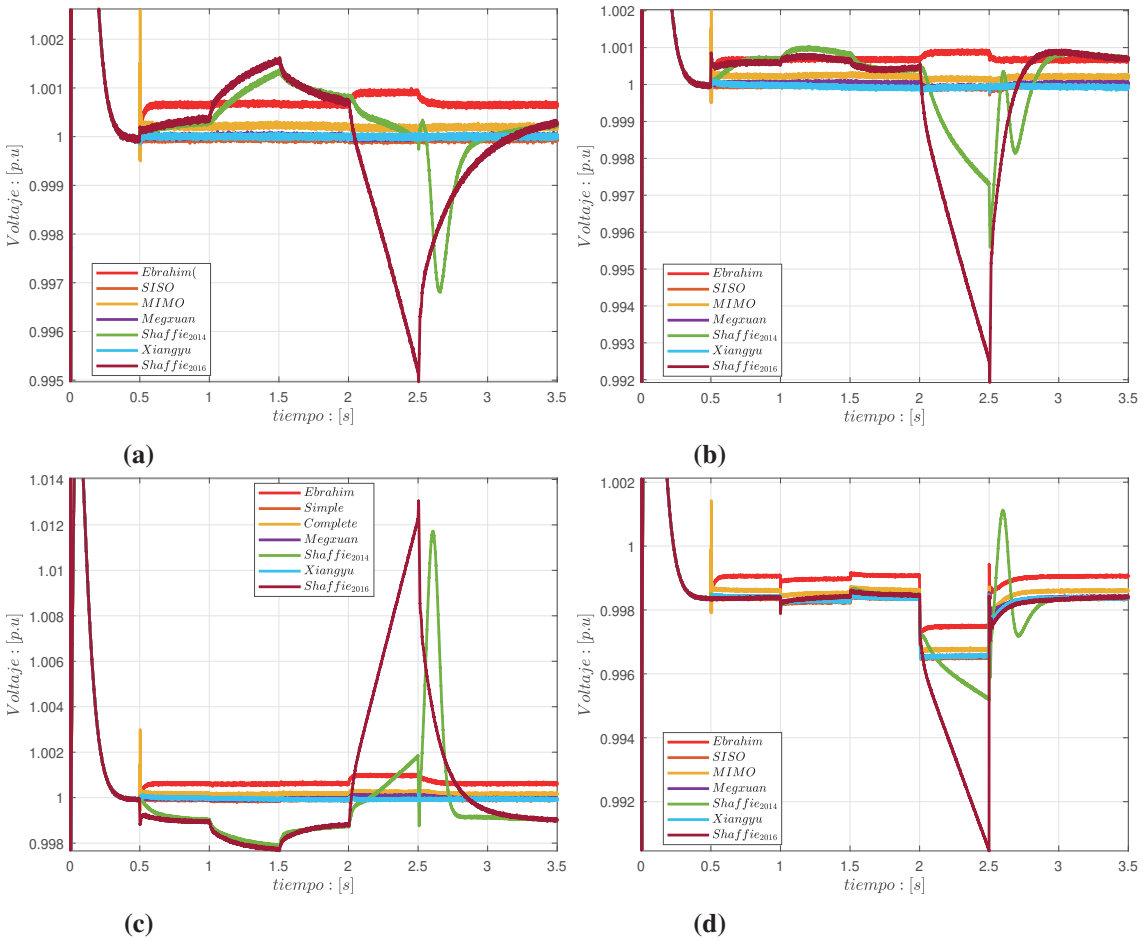

Figura 2.21: Curvas de respuesta de la red de prueba en magnitud de voltaje en Simulink: (a) GD_1, (b) GD_2, (c) GD_3, (d) Promedio de todos los nodos.

se observan diferencias notables en el desempeño de los controladores Megxuan, MRAC SISO y el controlador Xiangyu en ninguno de los generadores distribuidos.

Durante la tercera etapa (1-2 s), en la cual se alteran las cargas conectadas a los nodos, se observa que el fenómeno transitorio afecta de manera más pronunciada al GD_3. Esta mayor sensibilidad se debe al cambio de carga que ocurre precisamente en este nodo, lo que provoca variaciones en la tensión que son al menos el doble en comparación con los otros generadores. Además, es destacable que, independientemente del generador, los controladores más afectados por estas variaciones en todos los casos fueron los dos Shaffie. Esta situación se debe a que estos controladores utilizan como entrada el promedio de tensión de los nodos con generación. Asimismo, ambos están diseñados con un controlador adicional para gestionar la potencia reactiva, como se ilustra en la Figura 2.22, lo que conlleva a señales de control más significativas que generan un mayor error de estado estacionario y transitorios de mayor amplitud. Es relevante señalar que debido a esta razón,

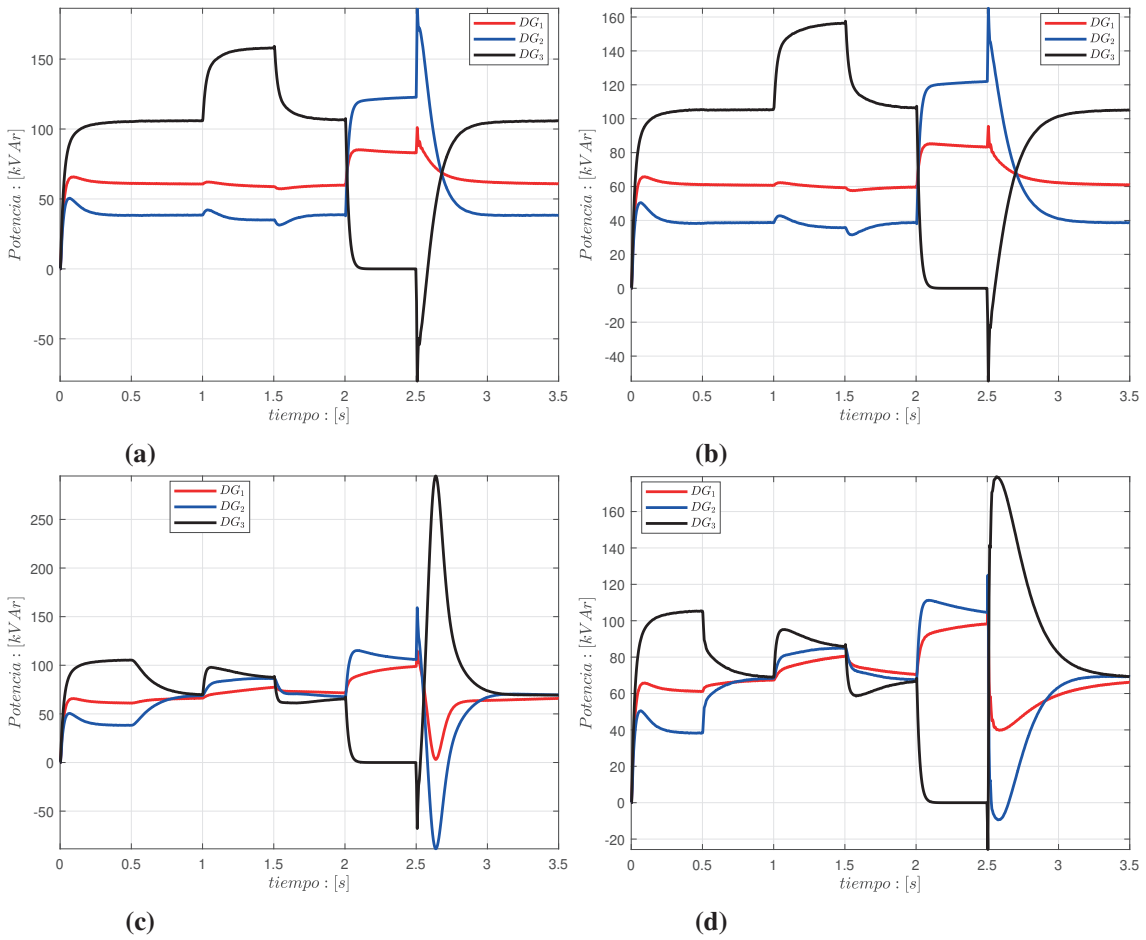

Figura 2.22: Curvas de respuesta de la red de prueba en potencia reactiva en Simulink: (a) Controlador Ebrahim, (b) Controlador Megxuan, (c) Controlador Shaffie 2014,(d) Controlador Shaffie 2016

los dos controladores presentan un tiempo de establecimiento más prolongado, ya que la falta de convergencia en la potencia impide que alcancen el estado estacionario al concluir la etapa, lo que a su vez provoca que la tensión no retorne a su magnitud original cuando la carga vuelve a su valor nominal.

Finalmente, en la cuarta etapa, se evidencia la mayor disparidad en el desempeño de los controladores. En esta etapa, se observan singularidades que afectan de manera desigual a unos controladores en comparación con otros. Un ejemplo claro de esto se observa en los dos controladores Shaffie, cuyo rendimiento se ve significativamente afectado por la desconexión del GD_3, mientras que la variación en los demás controladores es mínima. Esta discrepancia puede explicarse por el controlador adicional de potencia reactiva basado en el promedio, el cual, al intentar converger la potencia reactiva, incrementa notablemente la señal de control de potencia. Dicha señal está directamente relacionada con la señal de

control de voltaje, lo que provoca un aumento considerable en su magnitud hasta el punto de volver el sistema inestable si se prolonga la duración de esta etapa.

Por otra parte, es importante notar que los controladores que dependen de la medición de tensión en el punto de acople común (PCC), como el controlador Ebrahim o aquellos distribuidos no basados en promedios (Xiangyu, Megxuan), se vieron significativamente menos afectados por los escenarios de prueba realizados. La razón detrás de esto obedece a que, la señal de control recibida depende casi exclusivamente del punto de acople común, que es un nodo diferente al que se aplicaron las pruebas. En el caso de los controladores distribuidos no basados en promedio, el buen desempeño radica en que, al no depender de un punto en específico sino de la información compartida con sus vecinos, la influencia de un solo generador o nodo no es es lo suficientemente significativa para afectar en gran medida el funcionamiento de los controladores. Entonces, las perturbaciones se contrarrestan aún más al ser señales de control independientes para cada generador. Igualmente, es importante mencionar que debido a su desempeño en general y a que no presentan un punto de fallo único, se recomienda el uso de un controlador para voltaje distribuido sin control de potencia reactiva basada en promedio, como el Xiangyu, sobre el resto.

En cuanto al control secundario de frecuencia, representado en la Figura 2.23, durante la primera etapa se observa que el control primario exhibe un error de estado estacionario mayor en la frecuencia, con $0.006\,Hz$. Este error se reduce aproximadamente a la mitad en la etapa dos con la incorporación del controlador secundario. Se destaca el desempeño de los controladores Xiangyu y Shaffie 2014, que muestran un mínimo sobrepaso y un error de estado estacionario prácticamente nulo. Por otro lado, los controladores MRAC y Ebrahim presentan un mayor sobrepaso debido al uso de un PLL (phased Locked Loop) para medir la frecuencia del PCC, que puede ser agresivo y muy sensible a los cambios de frecuencia. El controlador MRAC MIMO exhibe el peor desempeño, ya que la relación entre la frecuencia y la tensión no es significativa, lo que puede afectar su entrenamiento al carecer de suficientes referencias en su conjunto de entrenamiento.

En las etapas tres y cuatro (1-2 s), se observa que las variaciones de carga causaron cambios mayores en la frecuencia en comparación con los cambios en el voltaje, lo que sugiere una mayor robustez del controlador primario de voltaje ante perturbaciones. También se aprecian mayores variaciones en el desempeño de los controladores, lo que facilita una mejor comparación entre ellos. Todos los controladores, excepto los MRAC, lograron mantener el error de estado estacionario por debajo de $0.0001\ Hz$, con pequeños sobrepasos de menos de $0.002\ Hz$. El controlador Xiangyu mostró el mejor desempeño, sin alteraciones en el GD_1 y un desempeño igual o superior a los otros controladores en los GD_2 y GD_3.

En la etapa cinco (2-3.5 s), todos los controladores se vieron afectados significativamente por la conexión del GD_3, lo que provocó grandes transitorios de hasta $0.02\,Hz$. El GD_3 fue el más afectado al funcionar de manera autónoma, lo que se reflejó en transitorios considerablemente mayores que los observados en el GD_1 y GD_2. El controlador Megxuan mostró el mejor desempeño en este escenario, con transitorios hasta un 80 %, 50 % y 67 % menores que los otros controladores en los GD_1, GD_2 y GD_3, respectivamente. Por otro lado, los controladores MRAC SISO y MRAC MIMO exhibieron los mayores

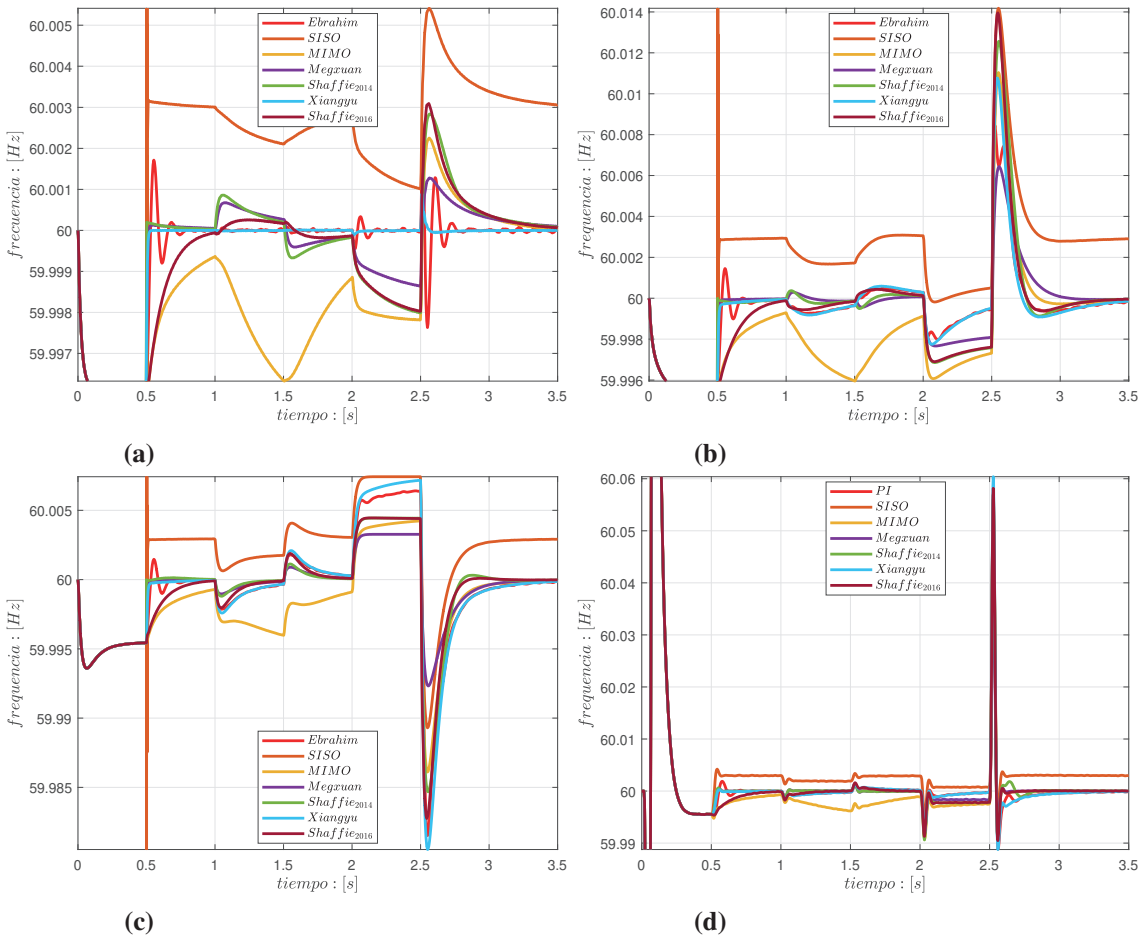

Figura 2.23: Curvas de respuesta de la red de prueba en magnitud de frecuencia en Simulink: (a) GD_1, (b) GD_2, (c) GD_3, (d) Promedio de todos los nodos

errores de estado estacionario y grandes sobrepasos. Es importante destacar que todos los controladores en los diferentes GDs se mantuvieron dentro de niveles adecuados para las normativas colombianas.

En el caso del promedio de frecuencia en los nodos, estos presentan sobrepasos significativamente mayores y, en general, un despesempeño peor, puesto que la frecuencia en cada uno de los nodos está medida con un PLL, el cual es muy sensible ante transitorios y cambios en la frecuencia. De igual forma, estos también se ven afectados por la distancia a la fuente de generación más cercana, por lo que los nodos más lejanos o con mayores inductancias tenderán a una frecuencia más alejada de la frecuencia nominal.

No obstante, el análisis elaborado resulta insuficiente para definir con certeza el controlador con el mejor desempeño. Por lo tanto, las respuestas en tensión y frecuencia obtenidas de cada uno de los controladores se miden teniendo en cuenta los siguientes índices cuantitativos: i) la integral del valor absoluto del error (IAE), ii) la integral del error al cuadrado

Tabla 2.4: Métricas de comparación de controladores centralizados en Simulink

	Métrica	**Ebrahim**	**SISO**	**MIMO**
Frecuencia	$IAE[n]$	12.729	21.032	16.843
	$ISE[n]$	0.6859	0.7288	0.6939
	$IU[\mu]$	0.1249	0.2005	0.0932
Tensión	$IAE[m]$	16.978	16.978	16.978
	ISE	57.6135	57.6138	57.6137
	$IU[\mu]$	10.967	0.3725	0.1372
	$THD[\%]$	0.0788	0.0791	0.0800

Tabla 2.5: Métricas de comparación de controladores distribuidos en Simulink

	Métrica	**Megxuan**	**Shaffie**$_{2014}$	**Shaffie**$_{2016}$	**Xiangyu**
Frecuencia	$IAE[n]$	12.729	12.803	13.493	12.909
	$ISE[n]$	0.6639	7.1609	0.6891	0.6939
	$IU[\mu]$	0.8852	0.4360	0.6547	-0.5564
Tensión	$IAE[m]$	16.978	16.978	16.978	16.978
	ISE	57.6137	57.6138	57.6138	57.6138
	$IU[\mu]$	0.8488	-0.3512	0.6547	-0.4395
	$THD[\%]$	0.0786	0.0791	0.0793	0.0791

(ISE), iii) la integral de la señal de control (IU) y iv) la distorsión armónica en la señal trifásica de tensión (THD). Los resultados conseguidos se resumen en las Tablas 2.4 y 2.5. En frecuencia, el controlador MRAC SISO presentó el IAE más alto, mientras el controlar Shaffie 2014 evidenció el ISE más alto. Por su parte, el controlador Mexguan muestra el mejor desempeño, ya que obtuvo los menores IAE y ISE. No obstante, este controlador presentó la IU más alta, lo que demuestra su baja eficiencia energética. Del mismo modo, el controlador MRAC MIMO muestra el menor valor de IU, por lo que es el controlador con mayor ahorro de energía en la señal de control.

Ahora, si se consideran los indicadores en voltaje mostrados en las Tablas 2.4 y 2.5, se evidencia que todos los controladores generan valores de IAE y ISE muy cercanos entre sí, por lo que los indicadores no resultan útiles para evaluar su desempeño. Por otra parte, si se examina el IU es posible corroborar que los controladores con mejor eficiencia energética son el MRAC MIMO y el MRAC SISO. De igual forma, los controladores que más gastan energía según el IU, son el Ebrahim y el Mexguan. Por último, con respecto al THD, es factible decir que todos los controladores presentaron una baja distorsión armónica cumplimiento con los estándares emitidos por la IEEE. Sin embargo, el controlador Mexguan presenta la menor distorsión armónica y, por tanto, cumplen seguido muy de cerca por el

Ebrahim. Por otro lado, el controlador con el mayor THD fue el MRAC MIMO, seguido del Shaffie 2016.

2.7.4 Resultados en tiempo real

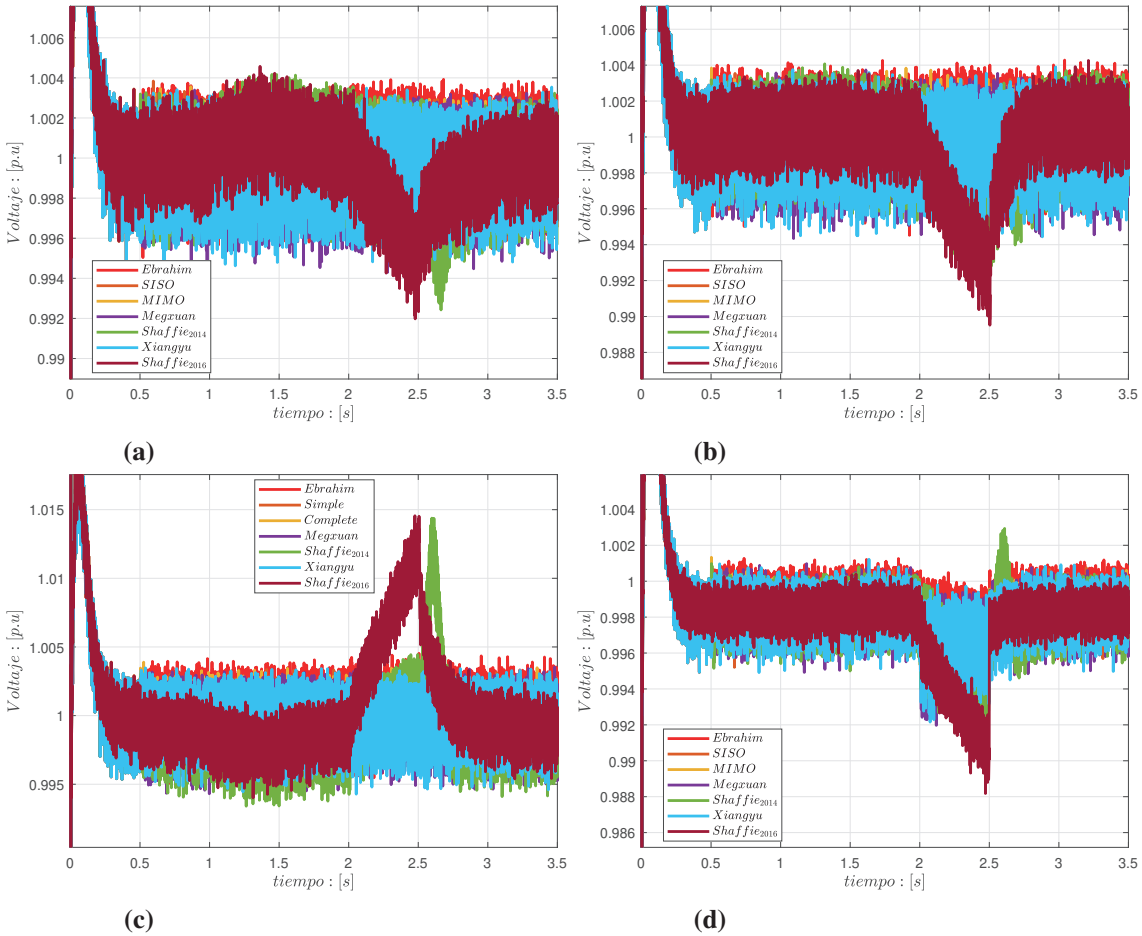

Figura 2.24: Curvas de respuesta de la red de prueba en magnitud de voltaje en la máquina de simulación en tiempo real: (a) GD_1, (b) GD_2, (c) GD_3, (d) Promedio de todos los nodos

En este escenario, la microrred de prueba es sometida a las mismas condiciones planteadas en la sección anterior, cuyas respuestas se presentan en las Figuras 2.24 y 2.25. En estas se puede notar que, a diferencia de las simulaciones realizadas en Simulink, estas presentan una respuesta con una distorsión armónica casi diez veces mayor. Lo anterior se debe al periodo de muestreo al que se ejecutan los controladores. Si bien es cierto que el control secundario puede actuar en tiempos de muestreo más altos, el control primario usado es

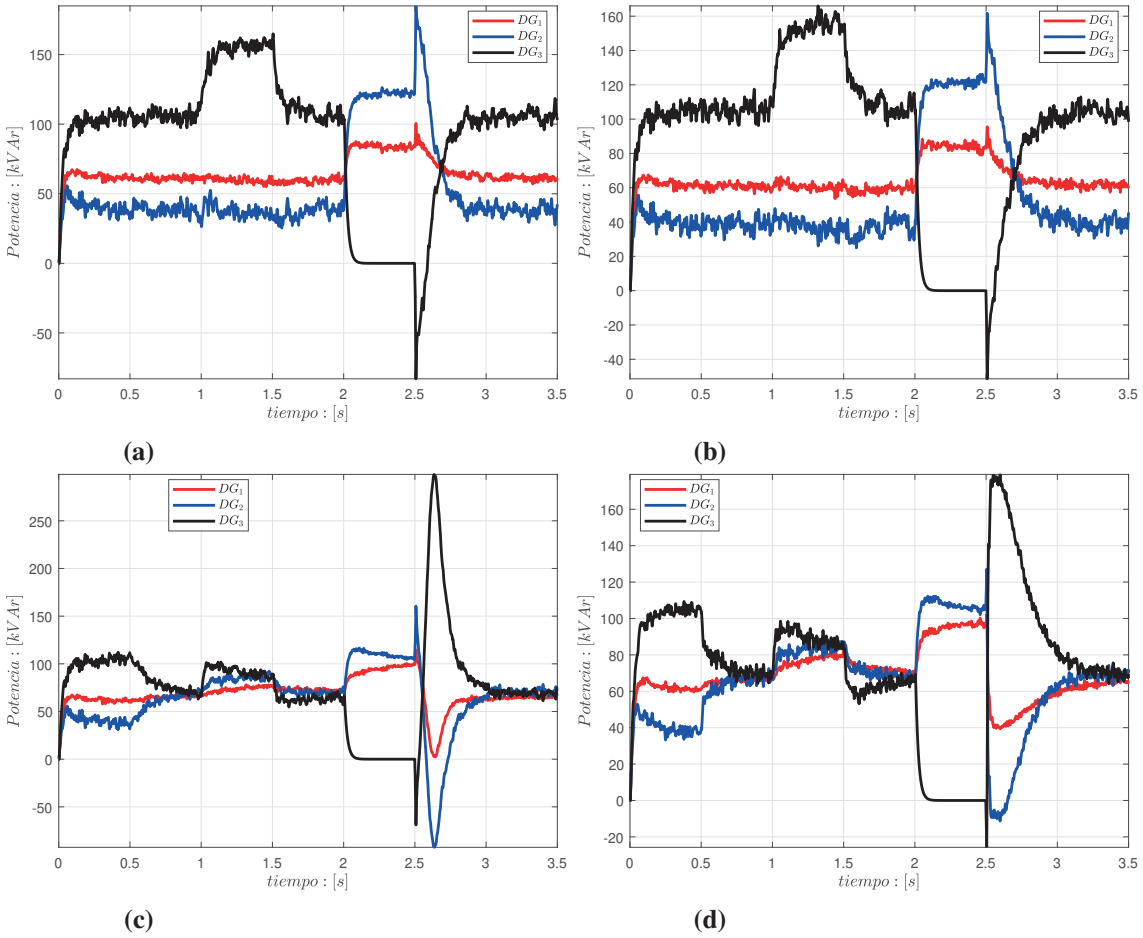

Figura 2.25: Curvas de respuesta de la red de prueba en potencia reactiva en la máquina de simulación en tiempo real: (a) Controlador Ebrahim, (b) Controlador Megxuan, (c) Controlador Shaffie 2014, (d) Controlador Shaffie 2016

significativamente más sensible al tiempo de muestro, lo que provoca que su desempeño empeore al no estar diseñado para estos tiempos de muestreo.

En la Figura 2.24, debido a la gran distorsión presentada, no es posible evidenciar diferencias notables en ninguno de los nodos de las GDs con excepción de los controladores Shaffie. Lo anterior se debe a que el efecto causado por los controladores secundarios es menor que la distorsión causada por el controlador primario, por lo cual no les fue posible mejorar la calidad de la tensión. Estos resultados se repiten en las etapas 1 a 5 (0-3.5 s) para la mayoría de controladores.

En cuanto a los controladores Shaffie, se puede observar que son los que se vieron más afectados por los escenarios de pruebas, al presentar las mayores variaciones en la etapa 5 (2-3.5 s). Tal como se explicó en la anterior sección, este desempeño se debe al control de convergencia de potencia reactiva que presentan, como se muestra en la Figura 2.25.

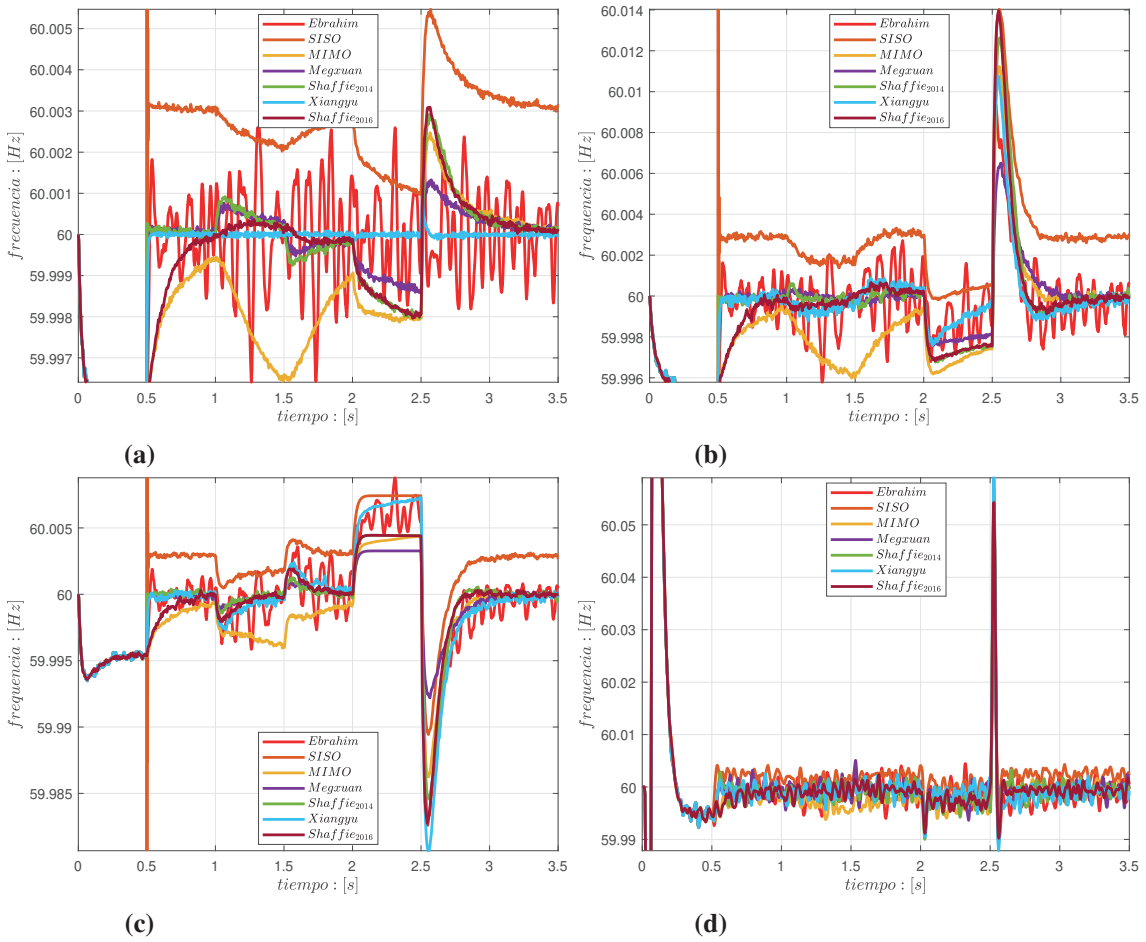

Figura 2.26: Curvas de respuesta de la red de prueba en magnitud de frecuencia en la máquina de simulación en tiempo real: (a) GD_1, (b) GD_2, (c) GD_3, (d) Promedio de todos los nodos

En cuanto al control secundario de frecuencia, el mayor cambio en todos los GDs se presenta en la GD_3 en las etapas 2 a 4, lo cual era de esperarse al ser el generador en el que se realizaron todas las pruebas. El cambio más significativo con las simulaciones realizadas en Simulink se da en el controlador Ebrahim, el cual presenta grandes oscilaciones y una mayor distorsión armónica que los otros controladores. Esto se debe al incremento en el tiempo de muestreo, ya que el control primario PI tiene un peor desempeño que causa oscilaciones en la magnitud de frecuencia. Además, este controlador en específico usa un PLL como medidor de frecuencia para su funcionamiento.

Cabe mencionar que, sin tener en cuenta el incremento de distorsión armónica en todos los controladores, los resultados obtenidos en RT-LAB no poseen diferencias significativas con las obtenidas con Simulink. El peor desempeño se presenta en el controlador MRAC SISO, seguido por el MRAC MIMO, cuyo bajo rendimiento puede deberse al rango tan

amplio escogido para el dataset de entrenamientos y la falta de datos más cercanos a las condiciones de funcionamiento ideales de la microrred. En cuanto al controlador MIMO, su bajo desempeño puede deberse a que la frecuencia y la tensión no poseen una relación significativa entre ellas y es por ello que se suelen emplear controladores independientes para cada variable.

Al igual que en la sección anterior, se examinó más a fondo las respuestas en tensión y frecuencia obtenidas en cada uno de los controladores teniendo en cuenta los mismos índices, cuyos resultados se resumen en las Tablas 2.6 y 2.7. En frecuencia el controlador MRAC SISO presentó el IAE más alto, mientras el controlar Shaffie 2014 evidenció el ISE más alto. Por su parte, el controlador Mexguan muestra el mejor desempeño, ya que obtuvo los menores IAE y ISE. No obstante, este controlador presentó la IU más alta, lo que demuestra la poca eficiencia energética del controlador. Del mismo modo, el MRAC MIMO muestra el menor valor de IU, por lo que es el controlador con mayor ahorro de energía en control. En comparación con la métricas obtenidas en Simulink, se puede notar que todos los indicadores aumentaron en al menos un factor de diez, lo cual se explica por las oscilaciones causadas por el cambio de tiempo de muestreo.

Si se consideran los indicadores en voltaje mostrados en las Tablas 2.6 y 2.7, se evidencia que todos los controladores generan valores de IAE y ISE similares. Por otra parte, si se examina el IU, es posible corroborar que los controladores con mejor eficiencia energética son el MRAC MIMO y el MRAC SISO. De igual forma, los controladores que más gastan energía según el IU son el Ebrahim y el Mexguan. Por ultimo, con respecto al THD, es factible decir que todos los controladores presentaron una baja distorsión armónica de acuerdo con los estándares. Sin embargo, el controlador Mexguan presenta la menor distorsión armónica, seguido muy de cerca por el Ebrahim. Por otro lado, el controlador con el mayor THD fue el MRAC MIMO, seguido del Shaffie 2016.

Tabla 2.6: Métricas de comparación centralizados Opal

	Métrica	**Ebrahim**	**SISO**	**MIMO**
Frecuencia	$IAE[\mu]$	0.1571	0.2072	0.1754
	$ISE[n]$	7.1850	7.5133	7.2092
	$IU[\mu]$	1.2501	2.0050	0.9594
Tensión	$IAE[m]$	169.781	169.781	169.781
	ISE	576.5136	576.5138	576.5137
	$IU[\mu]$	111.34	36.134	0.1372
	$THD[\%]$	0.5739	0.5639	0.5630

Tabla 2.7: Métricas de comparación distribuidos Opal

	Métrica	**Megxuan**	**Shaffie**$_{2014}$	**Shaffie**$_{2016}$	**Xiangyu**
Frecuencia	$IAE[\mu]$	0.1264	0.1390	0.1440	0.1398
	$ISE[n]$	6.9215	7.1609	7.1433	7.2243
	$IU[\mu]$	8.8202	4.5063	6.7753	-3.5335
Tensión	$IAE[m]$	169.78	169.78	169.78	169.78
	ISE	576.5138	576.5138	576.5138	576.138
	$IU[\mu]$	8.4596	-3.6641	6.7753	-2.3731
	$THD[\%]$	0.5735	0.5735	0.5634	0.5630

2.8 Limitaciones y trabajo futuro

Una de las limitaciones del trabajo presentado en esta capítulo radica en el enfoque de validación empleado. Si bien los controladores secundarios fueron evaluados en una plataforma de simulación en tiempo real Opal-RT, lo que permitió analizar su desempeño en escenarios más amplios que en una simulación convencional, no se realizó una validación experimental en un entorno físico. Esto impide evaluar con precisión el impacto de factores no modelados, como retardos en la comunicación, pérdidas en los convertidores y variaciones impredecibles en los parámetros del sistema. Asimismo, aunque se utilizaron indicadores de desempeño como el ISE, ITSE e IU para comparar los controladores, no se consideraron métricas relacionadas con la complejidad computacional ni el tiempo de convergencia, aspectos críticos para su implementación en sistemas con restricciones de procesamiento.

Como trabajo futuro, se propone la validación de los controladores en un banco de pruebas físico, lo que permitiría evaluar su desempeño bajo condiciones reales de operación. Además, sería relevante explorar la optimización de los controladores mediante técnicas avanzadas de aprendizaje automático, como redes neuronales recurrentes o enfoques basados en aprendizaje por refuerzo, con el objetivo de mejorar su capacidad de adaptación a escenarios dinámicos. También se sugiere analizar estrategias de control híbridas que combinen las ventajas de los enfoques centralizados y distribuidos, mejorando la resiliencia del sistema ante fallos y variaciones en la demanda. Finalmente, un estudio más detallado sobre el impacto de la complejidad computacional de cada controlador permitiría determinar su viabilidad en implementaciones de hardware con capacidad limitada.

2.9 Conclusiones

Este capítulo presenta una comparativa entre diferentes tipos de controladores secundarios, los cuales fueron implementados con éxito en una microrred de prueba. El análisis se realiza mediante el uso de indicadores como el ISE, ITSE y IU. Adicionalmente, se validan los

controladores propuestos en una plataforma de simulación en tiempo real Opal-RT, la cual posibilita el planteamiento de escenarios con ventanas de tiempo más grandes que en una simulación convencional. El controlador con el mejor desempeño en la microrred propuesta fue el Mengxuan, puesto que es robusto a los cambios en la carga y a los escenarios de desconexión y conexión del generador distribuido, además de presentar las oscilaciones más pequeñas. De igual forma, es relevante mencionar que el controlador con el peor desempeño fue el Shaffie del 2016. Se pudo constatar que la simulación basada en modelos matemáticos y la simulación en *software in the loop* en la plataforma de simulación tiempo real presentan resultados bastantes similares.

CAPÍTULO 3

CONTROL TERCIARIO: CONTROLADORES PREDICTIVOS PARA EL FLUJO ÓPTIMO DE POTENCIA

3.1 Resumen

El despacho óptimo de potencia es uno de los problemas que deben abordarse en el control de las microrredes para garantizar que operen de manera segura, confiable, eficiente y a un bajo costo. Una manera de afrontar este reto es incorporar estrategias que consideren el comportamiento estocástico de los sistemas y que se adapten a diferentes escenarios de operación. En este sentido, el presente capítulo propone un enfoque basado en control predictivo por modelo (MPC) para el despacho óptimo de potencia activa y reactiva en microrredes. Para ello, se presentan dos estrategias de gestión centralizadas que consideran los flujos tanto de potencia activa como de potencia reactiva dentro de las restricciones para encontrar soluciones que garanticen la convergencia de los flujos de carga. Los algoritmos propuestos optimizan los costos de operación, programan la carga y la descarga de las unidades de almacenamiento (UAs), regulan la tensión, disminuyen las pérdidas y garantizan el balance de potencia. También, se estudia un algoritmo distribuido para el despacho de potencia activa que consigue soluciones óptimas próximas a las del algoritmo centralizado, manteniendo tiempos de convergencia cortos. Adicionalmente, se establecen modelos de perdición de demanda y generación renovable mediante modelos autorregresivos integrados de media móvil (ARIMA) y se incorporan en los algoritmos propuestos. Para la validación se

emplea una versión modificada de la red IEEE de 13 nodos y un esquema de co-simulación entre Matlab® y DigSILENT®.

3.2 Introducción

El despacho óptimo de potencia en microrredes representa problemas de optimización que permiten establecer los puntos de operación de los generadores distribuidos (GDs) y de las unidades de almacenamiento (UAs) [77]. Formular y solucionar estos problemas son retos que deben abordarse para garantizar que las microrredes operen de manera eficiente, a un bajo costo e incrementen la seguridad y la confiabilidad [78]. Uno de los principales desafíos es establecer controladores capaces de afrontar la incertidumbre, originada principalmente por la naturaleza estocástica tanto de la generación renovable como de las dinámicas de consumo de los usuarios. Para lo anterior, se debe realizar una correcta gestión del almacenamiento de energía, de tal forma que se consoliden estrategias de gestión robustas ante perturbaciones como variaciones en la generación y en la demanda [79].

Por otra parte, también es necesario desarrollar controladores que se adapten a los diferentes ambientes de gestión, como las microrredes constituidas por sistemas energéticos comunitarios [80]. En estas topologías de microrred es común integrar diferentes sistemas de generación mediante técnicas de control distribuido, logrando gestionar el conjunto a partir de la integración de controles locales [81]. Sin embargo, aún es un reto para la investigación desarrollar algoritmos distribuidos que garanticen soluciones óptimas, con un mínimo intercambio de información entre controladores y en tiempos de convergencia cortos [81], [82].

En la literatura se ha abordado el problema del despacho óptimo de diferentes maneras. Los métodos heurísticos han sido ampliamente utilizados debido a la no linealidad de los problemas. Por ejemplo, en [83] se realiza el despacho económico mediante algoritmos genéticos y en [84], [85] mediante optimizacion por enjambre de particulas (PSO - *Particle Swarm Optimization*). Si bien estos métodos no requieren simplificaciones en los problemas de optimización, no garantizan la convergencia a óptimos globales y los tiempos de convergencia son elevados para aplicaciones en tiempo real [77], lo que también complica la incorporación de modelos predictivos. Otros estudios se han enfocado en proponer linealizaciones que permiten formular problemas de optimización convexos para garantizar la convergencia de métodos como el de punto interior y la programación lineal [86], [87]. Estas estrategias presentan tiempos de convergencia menores y son aplicables a grandes sistemas de potencias, pero no son robustas ante la presencia de incertidumbre.

Métodos más robustos se consiguen al incorporar un horizonte de pronóstico y utilizar técnicas como el control predictivo por modelo (MPC - *Model Predictive Control*) en los problemas de despacho. Estos controladores mantienen tiempos de convergencia cortos y permiten programar la carga y la descarga de las UAs, anticipando variaciones en el consumo, la generación y el precio de la energía. En [88], [89] se emplea MPC para el despacho económico de potencia activa. El primero considera la incertidumbre de la demanda y la generación renovable, mientras que el segundo añade la del precio de la

energía. Otros estudios, como los realizados en [78], [90], proponen modelos para relacionar costos de generación a la potencia reactiva y aplicar MPC para el despacho conjunto de potencia activa y reactiva.

En la literatura generalmente se validan los algoritmos con horizontes de pronóstico ideales [78], [88]-[90] y se trabaja los modelos de predicción como un problema de investigación por separado. En la predicción de recursos energéticos renovables es común emplear modelos de inteligencia artificial como redes neuronales [91]-[93] y aprendizaje automático [94]. Sin embargo, estos métodos requieren de bases de datos extensas que permitan el entrenamiento de los modelos, por lo que algunos estudios se inclinan hacia el uso de regresiones temporales, tanto para el pronóstico de perfiles de consumo, como para la predicción de recursos energéticos [95], [96].

Por otro lado, los métodos de optimización distribuida también han sido ampliamente estudiados en los problemas de despacho. En estas técnicas, la gestión de toda la microrred se realiza solucionando un conjunto de subproblemas, cada uno correspondiente a controles locales de sistemas de generación relativamente independientes [97]. Existen diferentes métodos para distribuir algoritmos que pueden extenderse a los problemas de despacho. Por ejemplo, [98]-[100] emplean el método de dirección alterna de multiplicadores (ADMM - *Alternating Direction Method of Multipliers*) para el despacho económico de potencia activa. El trabajo realizado en [101], plantea una estrategia distribuida basada en el método de dinámica de replicadores para el despacho conjunto de potencia activa y reactiva, de tal forma que se minimizan costos de operación y pérdidas por distribución. Finalmente, en [79], [97], [102] ya se desarrollan controladores MPC distribuidos para el despacho económico de potencia activa. El primer trabajo propone una estrategia a partir de un sistema multi-agente, el segundo emplea los principios de la teoría de juegos y el tercero una combinación de técnicas de consenso y la descomposición dual.

En este capítulo, se presenta una estrategia MPC para la gestión centralizada y distribuida de microrredes. Los métodos presentados son capaces de realizar despacho económico, garantizar el balance de potencia, programar la carga y la descarga de las UAs, disminuir las pérdidas por distribución y regular la tensión.

El contenido de este capítulo comprende los siguientes aspectos:

- La formulación de dos problemas de optimización para el despacho conjunto de potencia activa y reactiva.

- Dos algoritmos MPC centralizados fáciles de extender a diferentes escenarios de operación y capaces de encontrar puntos de operación óptimos, anticipando fenómenos como picos de consumo y reducciones en la generación.

- Un modelo y un algoritmo que permiten distribuir un MPC centralizado para el despacho de potencia activa manteniendo tiempos de convergencia cortos.

- El desarrollo de modelos de predicción para el pronóstico de generación renovable y demanda.

- La validación de los algoritmos en un esquema de co-simulación e incluyendo modelos de predicción.

3.3 MPC centralizado para el flujo óptimo de potencia

En la gestión centralizada, existe un único control encargado de establecer los puntos de operación de los GDs y las UAs de una microrred, como se detalla en la Figura 3.1, en donde se resumen los requerimientos para el diseño de controladores predictivos y la arquitectura de un controlador centralizado. En la gestión de un sistema bajo el enfoque MPC, las acciones de control se establecen considerando predicciones futuras de las variables que generan incertidumbre [79]. Para ello, es necesario establecer un modelo dinámico de la microrred que permita la incorporación de modelos de predicción. Por consiguiente, en esta sección se desarrollan modelos de optimización para el despacho económico de potencia activa y la minimización de pérdidas mediante la gestión de la potencia reactiva. De igual manera, se definen los algoritmos que permiten la gestión predictiva de la microrred.

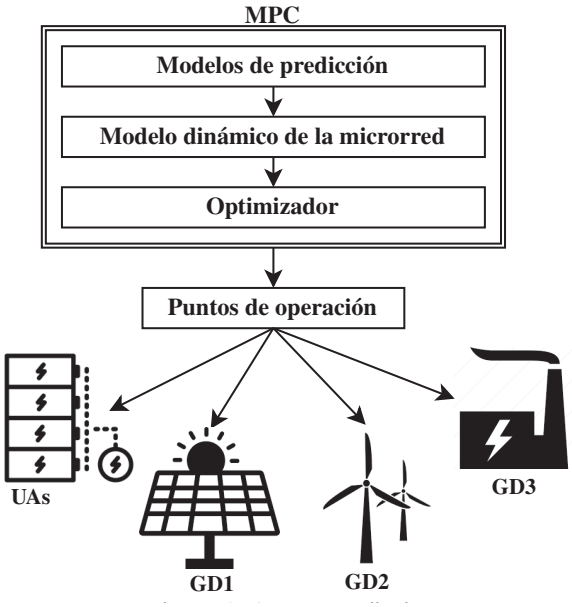

Figura 3.1: Requerimientos de los controladores MPC y topología de una microrred de gestión centralizada

3.3.1 Despacho económico de potencia activa

El despacho económico de potencia activa optimiza el sistema al minimizar los costos, utilizando la potencia disponible de los generadores más eficientes y compensando cualquier déficit con aquellos de mayor costo [77]. Para ello, es necesario establecer una función objetivo que modele los costos por generación de los diferentes GDs. Según [103], una

buena aproximación del costo del i-ésimo generador C_i^G se consigue a partir de funciones cuadráticas dependientes de la potencia activa generada,

$$c_i^G(p_i) = a_i p_i^2 + b_i p_i + c_i, \tag{3.1}$$

donde a_i, b_i y c_i son parámetros específicos de cada GD. De igual manera, las UAs también tienen relacionado un costo. En este trabajo solo se considera el costo por descarga, puesto que, la potencia que carga las baterías ya tiene un costo asociado cuando es generada. Un modelo simplificado para incluir los costos de las UAs en función de la potencia de descarga p_j^{dis} se adapta de [104] como:

$$c_j^B(p_j^{\text{dis}}) = b_j p_j^{\text{dis}}, \tag{3.2}$$

$$b_j = \frac{c_j^{\text{inv}}}{4(c_j^f)(n_j^{\text{dis}})}, \tag{3.3}$$

donde n_j^{dis}, c_j^{inv}, y c_j^f corresponden a la eficiencia de descarga, al costo de inversión y a los ciclos de vida de la unidad de almacenamiento j, respectivamente. Luego, si el sistema tiene N_g generadores y N_b unidades de almacenamiento, la función objetivo para el despacho económico de potencia activa está dada por:

$$C\left(p_i, p_j^{\text{dis}}\right) = \sum_{i=1}^{N_g} c_i^G(p_i) + \sum_{j=1}^{N_b} c_j^B(p_j^{\text{dis}}). \tag{3.4}$$

Adicionalmente, los problemas de despacho están sujetos a restricciones que establecen las condiciones de operación de la microrred. La primera restricción consiste en el equilibrio de potencia, asegurando que en cada momento de gestión, la potencia total despachada busque satisfacer tanto la demanda de potencia de las cargas p^L como las pérdidas p^{loss}. Matemáticamente se expresa como:

$$\sum_{i=1}^{N_g} p_i + \sum_{j=1}^{N_b} p_j = p^L + p^{\text{loss}}. \tag{3.5}$$

La variable p_j depende de la potencia de descarga $p_j^{\text{dis}} > 0$ cuando la UA entrega potencia, y de la potencia de carga $p_j^{\text{ch}} < 0$ cuando la UA demanda potencia para almacenar. Según [105], una forma de establecer la potencia activa en las UAs es

$$p_j = n_j^{\text{ch}} p_j^{\text{ch}} + \frac{p_j^{\text{dis}}}{n_j^{\text{dis}}};\ \forall j \in \{1, \cdots, N_b\}, \tag{3.6}$$

donde n_j^{ch} es la eficiencia de carga y n_j^{dis} la de descarga.

También, en los GDs y las UAs es necesario restringir los límites de operación para asegurar que trabajen en los intervalos $[p^{\text{min}}, p^{\text{max}}]$ permitidos. En consecuencia, la segunda y la tercera restricción para N_g generadores y N_b bancos de baterías se definen como:

$$p_i^{\text{min}} \leq p_i \leq p_i^{\text{max}};\ \forall i \in \{1, \cdots, N_g\}, \tag{3.7}$$

$$p_j^{\min} \leq p_j \leq p_j^{\max};\ \forall j \in \{1, \cdots, N_b\}. \tag{3.8}$$

Es válido aclarar que los límites máximos en los generadores renovables varían de acuerdo con los recursos energéticos disponibles en cada instante de tiempo.

Finalmente, en las unidades de almacenamiento, los límites en los estados de carga son dinámicos y vienen dados por:

$$E_j^{\min} \leq E_j(t+1) \leq E_j^{\max};\ \forall j \in \{1, \cdots, N_b\}, \tag{3.9}$$

donde $E^{\min}$ es la capacidad mínima, $E^{\max}$ es la capacidad máxima y $E(t+1)$ representa el estado de carga siguiente, que se obtiene a partir del estado de carga actual $E_j(t)$ mediante:

$$E_j(t+1) = E_j(t) + p_j;\ \forall j \in \{1, \cdots, N_b\}. \tag{3.10}$$

Luego, si se reescribe la ecuación (3.9) a partir de (3.10), las restricciones para el estado de carga de las UAs son:

$$-p_j \leq -E_j^{\min} + E_j(t);\ \forall j \in \{1, \cdots, N_b\}, \tag{3.11}$$

$$p_j \leq E_j^{\max} - E_j(t);\ \forall j \in \{1, \cdots, N_b\}. \tag{3.12}$$

3.3.2 Modelo predictivo

Las UAs hacen posible la aplicación de controladores MPC en la gestión energética de las microrredes. Para ello, es necesario extender el problema de optimización en un horizonte tiempo $H = \{t_0, ..., t_f\}$, de tamaño H_p, para establecer un modelo predictivo. Lo anterior permite programar la carga y la descarga de los bancos de baterías a modo de respuesta a perturbaciones como picos de consumo y variaciones en la capacidad de generación, mejorando la disponibilidad del servicio. En este sentido, el modelo predictivo derivado del problema de despacho de potencia activa está definido por:

$$\underset{p_i, p_j}{\text{minimizar}}$$

$$C_{MPC}\left(p_{it}, p_{jt}\right) = \sum_{t=1}^{H_P} \sum_{i=1}^{N_g} c_i^G(p_{it}) + \sum_{t=1}^{H_P} \sum_{j=1}^{N_b} c_j^B(p_{jt}^{\text{dis}}), \tag{3.13}$$

Sujeto a:

$$\sum_{i=1}^{N_g} p_{it} + \sum_{j=1}^{N_b} p_{jt} = p_t^L + p_t^{\text{loss}} \tag{3.14}$$

$$p_i^{\min} \leq p_{it} \leq p_i^{\max}; \qquad \forall i \in \{1, \cdots, N_g\} \tag{3.15}$$

$$p_j^{\min} \leq p_{jt} \leq p_j^{\max}; \qquad \forall j \in \{1, \cdots, N_b\} \tag{3.16}$$

$$-p_{jt} \leq -E_j^{\min} + E_j(t-1); \qquad \forall j \in \{1, \cdots, N_b\} \tag{3.17}$$

$$p_{jt} \leq E_j^{\max} - E_j(t-1); \qquad \forall j \in \{1, \cdots, N_b\} \tag{3.18}$$

$$p_{jt} = n_j^{\text{ch}} p_{jt}^{\text{ch}} + \frac{p_{jt}^{\text{dis}}}{n_j^{\text{dis}}}; \qquad \forall j \in \{1, \cdots, N_b\} \tag{3.19}$$

$$E_j(0) = E_{j0}, \tag{3.20}$$

en el que, E_{jo} es el estado de carga inicial de la UA j. p_{it}, p_{jt}, y $E_j(t)$ son la potencia del generador i, la potencia de la batería j y el estado de carga de la batería j en el instante de tiempo t, respectivamente. Por consiguiente, como $t \in H$, cada restricción (3.14)-(3.19) conlleva H_p restricciones.

3.3.3 Despacho de potencia reactiva - Modelo real

El despacho de potencia reactiva tiene como propósito corregir los perfiles de voltaje y minimizar las pérdidas por distribución. En una microrred aislada con N_n nodos y con N_k nodos conectados al nodo k, una función objetivo que aproxima las pérdidas de potencia activa, puede calcularse según [106] como:

$$p_R^{\text{loss}}(v, \theta) = \sum_{k=1}^{N_n} \sum_{m=1}^{N_k} g_{km}(v_k^2 + v_m^2 - 2v_k v_m \cos(\theta_k - \theta_m)), \tag{3.21}$$

donde, v_k, v_m, θ_k y θ_m son los voltajes y los ángulos de fase de los nodos k y m, respectivamente, conectados por el elemento en serie (líneas de trasmisión, transformadores, interruptores, entre otros), (k, m) con conductancia g_{km}.

Las restricciones de igualdad son determinadas por el flujo de carga, definido en [106] por:

$$\begin{aligned} p_k(v, \theta) &= v_k \sum_{m=1}^{N_k} v_m (g_{km}^{\text{bus}} \cos(\theta_k - \theta_m) + b_{km}^{\text{bus}} \sin(\theta_k - \theta_m)) \\ &= p_k^G - p_k^L; \ \forall k \in \{1, \cdots, N_n\}, \end{aligned} \tag{3.22}$$

$$\begin{aligned} q_k(v, \theta) &= v_k \sum_{m=1}^{N_k} v_m (g_{km}^{\text{bus}} \sin(\theta_k - \theta_m) - b_{km}^{\text{bus}} \cos(\theta_k - \theta_m)) \\ &= q_k^G - q_k^L; \ \forall k \in \{1, \cdots, N_n\}, \end{aligned} \tag{3.23}$$

donde, p_k^G, q_k^G, p_k^L y q_k^L son las potencias generadas y demandadas en el nodo k, respectivamente. $p_k(v,\theta)$ y $q_k(v,\theta)$ representan el flujo activo y reactivo en el nodo k. Si el flujo es positivo, el nodo está entregando potencia, en caso contrario está consumiendo. Los parámetros g_{km}^{bus} y b_{km}^{bus} se derivan de la conductancia g_{km} y la susceptancia b_{km} de los elementos en serie que conectan los nodos. Según [107], una forma de estimar estos parámetros es a partir de la admitancia y_{km}, de la siguiente manera:

$$y_{km} = g_{km} + jb_{km},$$

$$y_{km}^{\text{bus}} = \begin{cases} -y_{km} & si \quad k \neq m \\ y_{km} + \sum_{k=1}^{N_k} y_{km} & si \quad k = m, \end{cases} \tag{3.24}$$

$$g_{km}^{\text{bus}} = \Re(y_{km}^{\text{bus}}), \tag{3.25}$$

$$b_{km}^{\text{bus}} = \Im(y_{km}^{\text{bus}}). \tag{3.26}$$

Finalmente, si se asume que el nodo i se encuentra en fase y no presenta desviación en relación al nodo slack, una aproximación lineal de las ecuaciones (3.22) y (3.23) según [108] es:

$$\sum_{m=1}^{N_k} \left(g_{km}^{\text{bus}} v_m - b_{km}^{\text{bus}} \theta_m\right) = p_k^G - p_k^L;\ \forall k \in \{1, \cdots, N_n\}\ , \tag{3.27}$$

$$\sum_{m=1}^{N_k} \left(-b_{km}^{\text{bus}} v_m - g_{km}^{\text{bus}} \theta_m\right) = q_k^G - q_k^L;\ \forall k \in \{1, \cdots, N_n\}, \tag{3.28}$$

las cuales se pueden escribir de manera matricial como

$$G^{\text{bus}} V - B^{\text{bus}} \theta - P^{G_N} = -P^{L_N}, \tag{3.29}$$

$$-B^{\text{bus}} V - G^{\text{bus}} \theta - Q^{G_N} = Q^{L_N}, \tag{3.30}$$

donde G^{bus} y B^{bus} son matrices de tamaño $N_n \times N_n$, correspondientes a las g_{km}^{bus} y b_{km}^{bus} de todos los elementos en serie de la microrred. Además, P^{G_N}, Q^{G_N}, Q^{L_N} y Q^{L_N} son vectores con N_n elementos de las potencias generadas y demandadas en los nodos, V es el vector de magnitudes de voltaje de nodo y θ el vector de ángulos de fase.

Por otro lado, los límites de operación de las variables establecen las siguientes restricciones de desigualdad:

- Límites de Tensión

$$v_i^{\text{min}} \leq v_i \leq v_i^{\text{max}};\ \forall i \in \{1, \cdots, N_n\}. \tag{3.31}$$

- Límites de fase

$$\theta_i^{\text{min}} \leq \theta_i \leq \theta_i^{\text{max}};\ \forall i \in \{1, \cdots, N_n\}. \tag{3.32}$$

- Límites de operación

$$q_i^{\text{min}} \leq q_i \leq q_i^{\text{max}};\ \forall i \in \{1, \cdots, N_g\}, \tag{3.33}$$

$$q_j^{\min} \leq q_j \leq q_j^{\max};\ \forall j \in \{1, \cdots, N_b\}. \tag{3.34}$$

Las unidades de almacenamiento despachan potencia reactiva tanto en estado de carga como en descarga [109], [110] y sus límites de generación son dinámicos. En un banco de baterías, los limites reactivos varían dependiendo de la potencia activa y del factor de potencia FP asociado al inversor. Por lo tanto, es necesario establecer la restricción

$$q_j^{\max} = -q_j^{\min} = |p_j| \tan(\cos^{-1}(FP_j));\ \forall j \in \{1, \cdots, N_b\}. \tag{3.35}$$

Luego, como $p_j^{dis} \geq 0$ y $p_j^{ch} \leq 0$, una representación lineal de (3.35) es:

$$q_j^{\max} = -q_j^{\min} = C_j^{FP}\left(p_j^{dis} - p_j^{ch}\right);\ \forall j \in \{1, \cdots, N_b\}, \tag{3.36}$$

donde $C_j^{FP} = \tan(\cos^{-1}(FP_j))$.

3.3.4 Despacho de potencia reactiva - Modelo fasorial

Otra forma de plantear el problema de despacho de potencia reactiva es empleando modelos fasoriales, de tal forma que algunas variables como los voltajes v y la potencia aparente s se manejen en el plano complejo. La principal ventaja es que, de acuerdo con [107], las pérdidas por distribución se pueden aproximar mediante la función convexa

$$p_F^{\text{loss}}(V) = \Re\left(V^H Y^{\text{bus}} V\right), \tag{3.37}$$

donde $(.)^H$ representa la traspuesta conjugada, V es el vector de voltajes de nodo y Y^{bus} es la matriz de admitancias del sistema, que se construye a partir de la ecuación (3.24). En [107] también se define el flujo de potencia como:

$$\bar{s}_k = \sum_{m=1}^{N_k} \bar{v}_k y_{km}^{\text{bus}} v_m, \tag{3.38}$$

donde $\bar{v}_k$ representa el complejo conjugado de v_k y $s_k = p_k + jq_k$ es la potencia total aparente en el nodo k. Para incluir (3.38) dentro de las restricciones es necesario representarla como una ecuación afín, ya que los solvers como *cvx* y *Gurobi* que permiten trabajar con variables complejas exigen que los problemas sean convexos. En [86], [107] se recomienda la linealización de *Wirtinger* para aproximar el modelo a un conjunto convexo mediante el operador

$$f(z) \approx f(z_o) + \frac{\hat{\partial} f}{\partial z} \triangle z + \frac{\hat{\partial} f}{\partial \bar{z}} \triangle \bar{z}, \tag{3.39}$$

en el cual, $z = x + jy$ es la variable, z_0 es el punto alrededor del cual se linealiza, f es una función compleja de tipo $f(z) = u + jv$ y las derivadas se definen como

$$\frac{\hat{\partial} f}{\partial z} = \frac{1}{2}\left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y}\right) + \frac{j}{2}\left(\frac{\partial u}{\partial x} - \frac{\partial v}{\partial y}\right),$$

$$\frac{\hat{\partial} f}{\partial \bar{z}} = \frac{1}{2}\left(\frac{\partial u}{\partial x} - \frac{\partial v}{\partial y}\right) + \frac{j}{2}\left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y}\right).$$

Luego, linealizando (3.38) al rededor del punto v_{ko}, v_{mo}, la aproximación convexa del flujo de potencia es:

$$\sum_{m=1}^{N_k} y_{km}^{\text{bus}}(v_{m0}\bar{v}_k + \bar{v}_{k0}v_k - v_{m0}\bar{v}_{k0}) = \bar{s}_k^G - \bar{s}_k^L, \tag{3.40}$$

donde $\bar{s}_k^G$ y $\bar{s}_k^L$ son los complejos conjugados de la potencia aparente generada y la potencia aparente demandada en el nodo k, respectivamente.

Respecto a las restricciones relacionadas con los límites de operación de las variables, las que establecen los límites de generación ((3.33), (3.34) y (3.36)) se conservan. Sin embargo, para incluir los límites de voltaje es necesario definir un modelo convexo que reemplace a (3.31). Según [86], [107], estos límites pueden incluirse con la restricción

$$||v_i - v^{\text{nom}}|| \leq \delta v^{\text{nom}};\ \forall i \in \{1, \cdots, N_n\}, \tag{3.41}$$

donde v^{nom} es el voltaje nominal y δ la máxima desviación permitida. Adicionalmente, en este modelo es fácil añadir una restricción que limite la potencia aparente en los GDs, mediante la ecuación

$$||s_i|| \leq s_i^{max};\ \forall i \in \{1, \cdots, N_g\}. \tag{3.42}$$

Esta restricción es útil en GDs en los cuales los límites máximos de potencia activa y reactiva superan la máxima potencia aparente permitida.

3.3.5 Algoritmo MPC para despacho secuencial

Los controladores MPC se adaptan para solucionar los problemas de despacho de la siguiente manera: primero, se formula un problema de optimización para el despacho de potencia activa dentro de un horizonte de tiempo (propuesto en la Subsección 3.3.2). En segundo lugar, se resuelve este problema para determinar las potencias óptimas en cada momento dentro de ese horizonte. Tercero, se establecen los puntos de operación en potencia activa de los GD y las UAs tomando la primera acción de control, correspondiente al instante de tiempo t_0. Cuarto, se fijan las potencias activas generadas P^G como constantes y las Q^G como variables en las ecuaciones del flujo de carga. Finalmente, se resuelve el problema de optimización propuesto en la Subsección 3.3.3 o 3.3.4 para el despacho de potencia reactiva. El Algoritmo 3.1 resume el proceso descrito para K instantes de gestión.

3.3.6 Algoritmo MPC para despacho unificado

Otra forma de resolver el problema de despacho, es formular problemas de optimización que permitan la gestión conjunta de potencia activa y reactiva, aprovechando las linealizaciones de las ecuaciones del flujo de carga, como se muestra a continuación:

Algoritmo 3.1 MPC centralizado secuencial

Salida: Puntos de operación (p, q) en K instantes de gestión.
$H_p \leftarrow length\left([t_0, t_1, ..., t_f]\right)$ {Tamaño del horizonte de pronóstico}
$P_{\text{loss}} \leftarrow$ Establecer un valor inicial para las pérdidas
mientras $k \leq K$ **hacer**
1. $P_i^{\max} \leftarrow [P_{it_0}, P_{it1}, ..., P_{it_{H_p}}]; \forall i \in \{1, \cdots, N_g\}$ {pronóstico de perfiles de generación renovable}
2. $P^{\text{L}} \leftarrow [P_{t_0}^L, P_{t1}^L, ..., P_{t_{H_p}}^L]$ {Pronóstico de la demanda total agregada}
3. $P^{\text{opt}} \leftarrow$ Soluciones del problema definido en la Subsección 3.3.2.
4. $p_i \leftarrow P^{\text{opt}}(i, t_0); \forall i \in \{1, \cdots, (N_g + N_b)\}$ {Establecer la primera acción de control en cada GD y UA como los puntos de operación en potencia activa}
5. $p_{n_i}^G \leftarrow p_i$ {Calcular la potencia activa generada en cada nodo a partir de los p_i para establecer como constantes en las ecuaciones del flujo de carga. n_i corresponde al nodo en el cual está conectado el generador o la unidad de almacenamiento i}
6. $[Q^{\text{opt}}, V, \theta] \leftarrow$ Soluciones del problema definido en la Subsección 3.3.3 (solver: *fmincon* de *Matlab*) o 3.3.4 (solver: *cvx* con optimizador *Gurobi*).
7. $q_i \leftarrow Q^{\text{opt}}(n_i); \forall i \in \{1, \cdots, (N_g + N_b)\}$
8. $k \leftarrow k + 1$
$t_0 \leftarrow t_{0+1},\ t_f \leftarrow t_{f+1}$ {Horizonte de predicción para el siguiente instante de gestión}
fin mientras

- Modelo real

$$\underset{p,q}{\text{minimizar}}\ \alpha C_{MPC}\left(p_{ti}, p_{tj}\right) + \beta P_R^{\text{loss}}\left(v, \theta\right) \tag{3.43}$$

sujeto a:
(3.14), (3.15), (3.16), (3.17), (3.18), (3.19), (3.27), (3.28), (3.31), (3.33), (3.34)(3.36).

- Modelo fasorial

$$\underset{p,q}{\text{minimizar}}\ \alpha C_{MPC}\left(p_{ti}, p_{tj}\right) + \beta P_F^{\text{loss}}\left(V\right) \tag{3.44}$$

sujeto a:
(3.14), (3.15), (3.16), (3.17), (3.18), (3.19), (3.33), (3.34), (3.36), (3.40), (3.41), (3.42).

Los parámetros $\alpha > 0$ y $\beta > 0$ determinan los pesos que tienen los costos y las pérdidas en la función objetivo, respectivamente.

Las restricciones (3.14), (3.15), (3.16), (3.17), (3.18) y (3.19) están definidas en todo el horizonte $H = \{t_0, \ldots, t_f\}$, mientras que las restantes se fijan solo para el instante de

tiempo t_0. Por consiguiente, en las ecuaciones del flujo de carga (3.27), (3.28) y (3.40) si el GD o la UA i está conectado al nodo k, es necesario definir $p_k^G = p_{t_0 i}$, $q_k^G = q_i$ y $s_k^G = p_{t_0 i} + jq_i$, donde, $p_{t_0 i}$ y q_i son las variables correspondientes a la potencia activa y reactiva para el generador i en el instante de tiempo actual. El Algoritmo 3.2 establece los pasos a seguir para la gestión predictiva de microrredes mediante los modelos establecidos.

Algoritmo 3.2 MPC centralizado unificado

Salida: Puntos de operación (p, q) en K instantes de gestión.
$H_p \leftarrow length\,([t_0, t_1, ..., t_f])$ {Tamaño del horizonte de pronóstico}
mientras $k \leq K$ **hacer**
1. $P_i^{\max} \leftarrow [P_{it_0}, P_{it1}, ..., P_{it_{H_p}}]; \forall i \in \{1, \cdots, N_g\}$ {*pronóstico de perfiles de generación renovable*}
2. $P^{\mathrm{L}} \leftarrow [P_{t_0}^L, P_{t1}^L, ..., P_{t_{H_p}}^L]$ {*Pronóstico de la demanda total agregada*}
3. $(P^{\mathrm{opt}}, Q^{\mathrm{opt}}, V) \leftarrow$ Soluciones del problema definido en la ecuación (3.43) (solver: *fmincon* de Matlab) o (3.44) (solver: *cvx* con optimizador *Gurobi*).
4. $p_i \leftarrow P^{\mathrm{opt}}(i, t_0); \forall i \in \{1, \cdots, (N_g + N_b)\}$ {Puntos de operación en potencia activa}
5. $q_i \leftarrow Q^{\mathrm{opt}}(n_i); \forall i \in \{1, \cdots, (N_g + N_b)\}$ {Puntos de operación en potencia reactiva (n_i corresponde al nodo en el cual está conectado el generador o la unidad de almacenamiento i)}
6. $k \leftarrow k + 1$
$t_0 \leftarrow t_{0+1},\ t_f \leftarrow t_{f+1}$ {Horizonte de predicción para el siguiente instante de gestión}
fin mientras

3.3.7 Escenarios de simulación

Se realizan las siguientes modificaciones a la red IEEE de trece nodos [75] para evaluar los algoritmos propuestos: Primero, se reemplaza la red externa por un generador diésel. Segundo, a partir del estudio realizado en [111], se adicionan cuatro generadores distribuidos (un solar, un eólico y dos unidades de almacenamiento). Finalmente, se aproxima el sistema un modelo balanceado. La microrred conseguida se muestra en la Figura 3.2.

Los coeficientes de costos relacionados a (3.1) se muestran en la Tabla 3.1. La diferencia en los coeficientes relacionados con las unidades de almacenamiento surge debido a la inclusión de dos tecnologías: Li-Ion (BT1) y plomo ácido (BT2). Las primeras, aunque requieren un mayor costo de inversión, son aproximadamente un $30\,\%$ más eficientes y presentan un mayor número de ciclos de vida [112]. Estos valores varían de acuerdo con los escenarios o requerimientos de los usuarios, por lo que la diferencia de costos entre las UAs pueden ser ajustados a conveniencia.

La Tabla 3.2 detalla el factor de potencia y los límites de potencia activa de cada dispositivo. Los límites de las tensiones de nodo están fijados según la normativa colombiana en 0,95 p.u y 1,05 p.u y los límites de potencia reactiva se pueden estimar como:

$$q_i^{\max} = -q_i^{\min} = |p_i^{\max}| \tan(\cos^{-1}(FP)). \tag{3.45}$$

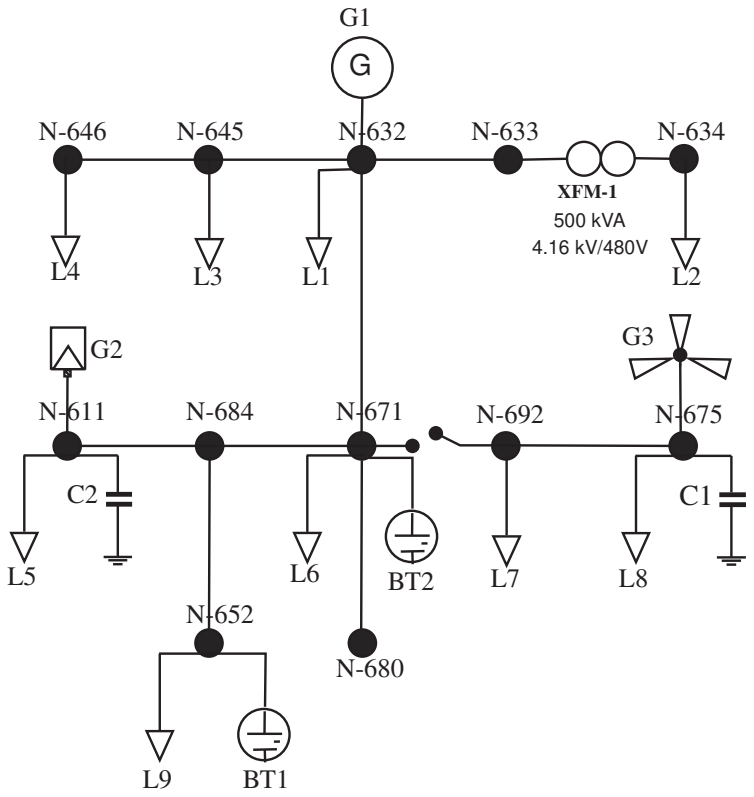

Figura 3.2: Esquema de la microrred basada en la red IEEE de 13 nodos.

Tabla 3.1: Coeficientes de costo para cada tipo de generador

Tipo de generador	$\mathbf{a}_i$	$\mathbf{b}_i$	$\mathbf{c}_i$
Diésel	104.44	1150.5	1.53
Fotovoltaico	28.77	400.00	0.00
Eólico	35.90	500.00	0.00
Unidad de almacenamiento-BT1	0.00	600.00	0.00
Unidad de almacenamiento-BT2	0.00	700.00	0.00

3.3.7.1 Demanda y recursos energéticos: A partir de las dinámicas de consumo medidas en la Universidad de Nariño y los valores nominales de las cargas presentados en [75], se estiman las curvas de demanda de las nueve cargas del sistema en diez días consecutivos, considerando tiempos de muestreo de una hora. La Figura 3.3 muestra la demanda total agregada, donde el fin de semana se identifica claramente por el bajo consumo de energía.

Las curvas de generación renovable (solar y eólico) se estiman acorde a los recursos energéticos disponibles en el campus universitario mostrados en la Figura 3.4, como en [77].

Tabla 3.2: Límites de capacidad y factor de potencia para cada GD y UA en la microrred.

GD/UA	Tipo	Pmax [kW]	Pmin [kW]	FP
G1	Diésel	2000	200	0.8
G2	Fotovoltaico	1300	0	0.8
G3	Eólico	1100	0	0.8
BT1	Banco de baterías	600	-600	0.8
BT2	Banco de baterías	400	-400	0.8

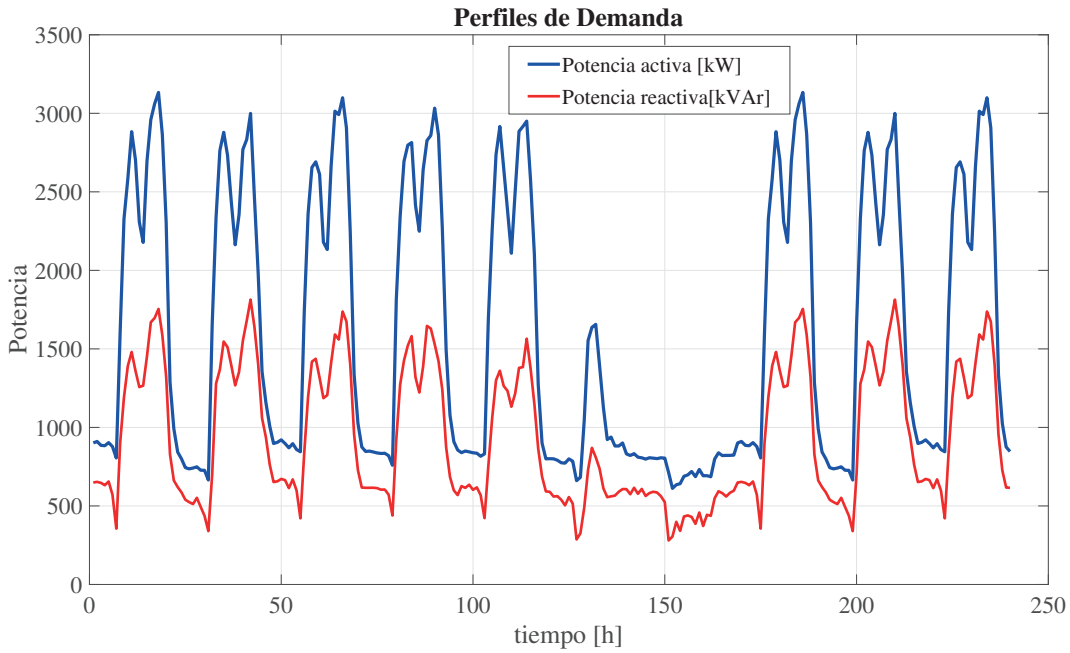

Figura 3.3: Demanda total agregada en diez días consecutivos.

Según [86], los perfiles de generación se pueden aproximar como:

$$P^{WT}(t) = \begin{cases} 0 & si \quad 0 < V_s(t) < V_R \\ P_{\text{nom}} \left(\frac{V_s(t)}{V_{\text{nom}}}\right)^3 & si \quad V_R \leq V_s(t) < V_{\text{nom}} \\ P_{\text{nom}} & si \quad V_{\text{nom}} \leq V_s(t) < V_{\text{max}} \\ 0 & si \quad V_s(t) \geq V_{\text{max}} \end{cases}$$

$$P^{PV}(t) = \rho_s R(t),$$

donde P^{WT} corresponde a la potencia generada por la turbina eólica, P_{nom} a la potencia

nominal, V_s a la velocidad del viento, V_R es la velocidad de arranque, V_{nom} la velocidad nominal y V_{max} es la velocidad máxima. Por otro lado, P_{PV} es la potencia generada por la estación solar, ρ_s es el coeficiente de productividad asociado a los paneles y R corresponde a la irradiancia en $\frac{W}{m^2}$. Los datos técnicos para la generación eólica se toman del generador Einar E70PRO [113] ($V_R = 2m/s$, $V_{\text{nom}} = 11m/s$ y $V_{\text{max}} = 60m/s$) y para la generación fotovoltaica se asume $\rho_s = 0.9$.

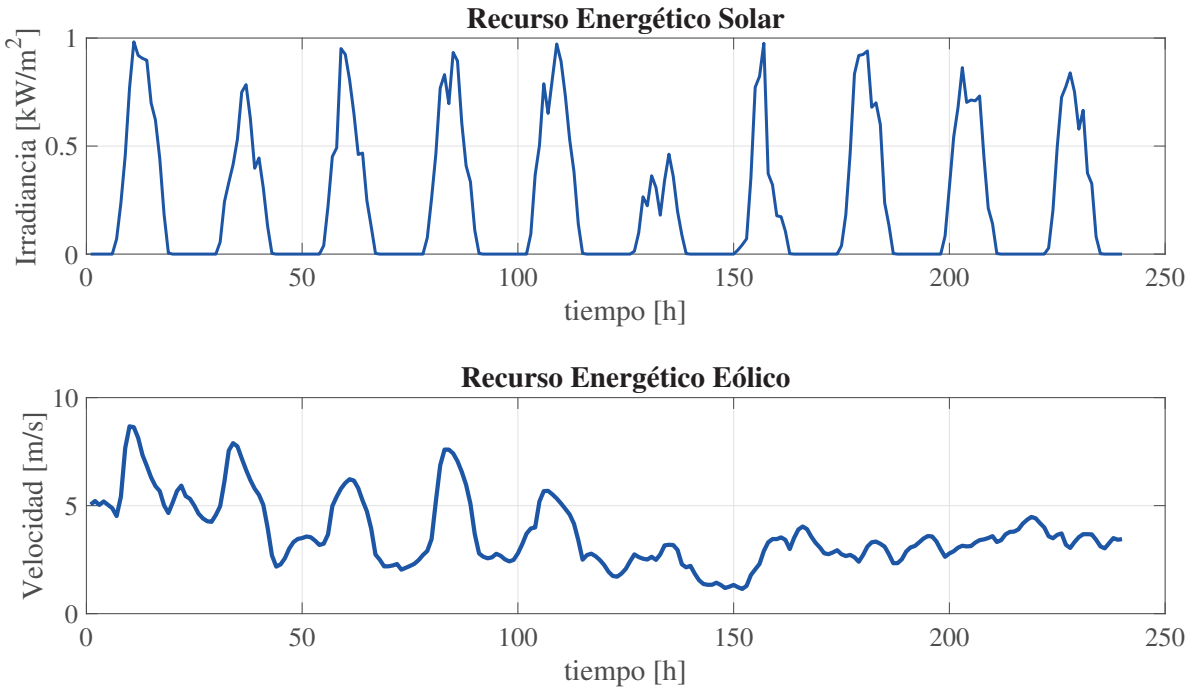

Figura 3.4: Ejemplo de recursos energéticos solar y eólico disponibles en la Universidad de Nariño durante diez días consecutivos.

3.3.8 Modelos de predicción

Con el fin de validar los controladores propuestos en ambientes más próximos a la realidad, en esta sección se desarrollan modelos de predicción para incorporar en los problemas de despacho.

En los escenarios establecidos en la sección anterior, las variables que generan incertidumbre son la generación solar, la generación eólica y la demanda. Por lo tanto, se diseñan modelos para el pronóstico de irradiancia, velocidad del viento y demanda de potencia activa. Para ello, se emplean modelos autorregresivos integrados de media móvil (ARIMA - *Autoregressive Integrated Moving Average*) como en [95], [96], los cuales son útiles cuando no se cuenta con bases de datos extensas de las variables.

3.3.8.1 Bases de datos: Las bases de datos de irradiancia y velocidad del viento se obtienen mediante el aplicativo *Renewables.ninja* [114], donde se encuentran disponibles de manera gratuita medidas correspondientes al año 2019 para cualquier parte del mundo. Los datos están tomados con tiempos de muestreo de 1h y es posible descargarlos filtrados, de tal forma que se corrijan o se eliminen medidas erróneas. Por otro lado, la base de datos de demanda se crea a partir del perfil de consumo de potencia activa detallado en la Figura 3.3. Para ello se varía aleatoriamente la potencia demandada en cada instante de tiempo, sumando o restando una cantidad aleatoria entre $\pm 30\,\%$ de la potencia requerida en ese instante.

3.3.8.2 Modelos ARIMA Los modelos autorregresivos de media móvil (ARMA - *Autoregressive Moving Average*) son procesos estocásticos empleados para el pronóstico en series temporales, donde el valor siguiente de la serie se determina a partir de una combinación lineal de valores pasados y parámetros de error [96]. Comúnmente, se representan como ARMA (p, q), donde p determina el número o orden del modelo autorregresivo (AR) y q el número o orden del modelo de medias móviles (MA). Matemáticamente, se puede expresar según [95] como:

$$\hat{y}_t = \sum_{i=1}^{p} \psi_i y_{t-i} + e_t + \sum_{j=0}^{q} \phi_j e_{t-j}, \tag{3.46}$$

donde, $\hat{y}_t$ es el valor pronosticado para el instante t, y_t es el valor observado en t, e_t es el error en t y ψ_i, ϕ_j son los parámetros autorregresivos y de media móvil que deben estimarse para entrenar el modelo. La condición necesaria para emplear modelos ARMA es que las series temporales sean estacionarias, es decir, que la media y la varianza sean constantes en el tiempo [115]. Sin embargo, los procesos estocásticos generalmente no son estacionarios, por lo que es necesario emplear métodos para conseguir representaciones estacionarias de las series de tiempo [95].

Los modelos ARIMA convencionales, incorporan el método de la diferenciación para corregir la falta de estacionariedad. Comúnmente se denotan como ARIMA (p, d, q), donde p presenta el orden del modelo autorregresivo y q el orden del modelo de media móvil, como se expresa en la ecuación (3.46), pero calculados después de que la serie se haya diferenciado d veces [96].

Una forma de establecer los parámetros p, d y q, es emplear métodos de optimización heurísticos estableciendo como función objetivo una función de evaluación de desempeño. En este trabajo se propone emplear un algoritmo PSO para encontrar los valores p, d y q y toolbox *Econometrics* de Matlab® para entrenar los modelos. Como función objetivo a minimizar se establece el error cuadrático medio (RMSE), definido en [96] como:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (y_i - \hat{y}_i)^2}, \tag{3.47}$$

donde N es igual al número de datos pronosticados, y_i el valor real y $\hat{y}_i$ el valor estimado. En el PSO se define una población de 20 individuos y los parámetros p, d y q se limitan a

240, 4 y 100, respectivamente. Luego, minimizando el RMSE de diez días consecutivos ($N = 240$) durante 20 iteraciones, se establecen los modelos de predicción detallados en la Tabla 3.3.

Tabla 3.3: Modelos de predicción

	Irradiancia $[W/m^2]$	**Velocidad del viento** $[m/s]$	**Demanda** $[kW]$	
			Semana	**Fin de semana**
Modelo	ARIMA ***(85,1,2)***	ARIMA (48,1,6)	ARIMA (240,1,2)	ARIMA (96,1,2)
RMSE	56.39	0.59	99.13	

Para el pronóstico de demanda se identifican dos dinámicas de consumo, una durante los días en semana y otra en los fines de semana, de tal forma que el consumo pronosticado para un fin de semana solo dependa del historial de consumo de los fines de semana, y que la predicción para un día en semana sea indiferente del consumo en los fines de semana. Las Figuras 3.5, 3.6 y 3.7 comparan los perfiles de demanda, irradiancia y velocidad del viento pronosticados con los medidos. En ellas se puede observar que el método propuesto para la predicción del recurso energético solar no es robusto ante cambios bruscos, presentando un error mayor de estimación cuando la irradiancia varía considerablemente con relación a los días anteriores. También se evidencia cómo, a pesar de que la velocidad del viento presenta un comportamiento estocástico más variante en el tiempo, el modelo propuesto consigue una aproximación aceptable, como lo evidencia la Tabla 3.3, en donde se muestran los RMSE totales para los diez días mostrados en las Figuras 3.5, 3.6 y 3.7.

3.3.9 Resultados y discusión

Se propone un esquema de co-simulación entre Matlab® y DigSilent® para validar los controladores planteados. En este esquema, DigSilent® estima las variables eléctricas mediante flujos de potencia, mientras que Matlab® se encarga de resolver los problemas de optimización y almacenar los datos de interés. El intercambio de información entre ambos programas se llevará a cabo mediante archivos .csv, como se describe en el diagrama de bloques de la Figura 3.8. Para solucionar los problemas de optimización definidos por los modelos reales, se emplea programación cuadrática secuencial (SQP- *Sequential Quadratic Programming*) mediante *fmincon*, función de Matlab® que permite incluir ecuaciones no lineales como (3.21), (3.22) y (3.23), aunque no trabaja con variables complejas. Por lo anterior, para los problemas de optimización definidos por los modelos fasoriales se emplea *cvx* estableciendo *Gurobi* como solucionador.

3.3.9.1 MPC Centralizado secuencial: El propósito de emplear técnicas de control predictivo en los problemas de despacho es programar la carga y la descarga de las UAs

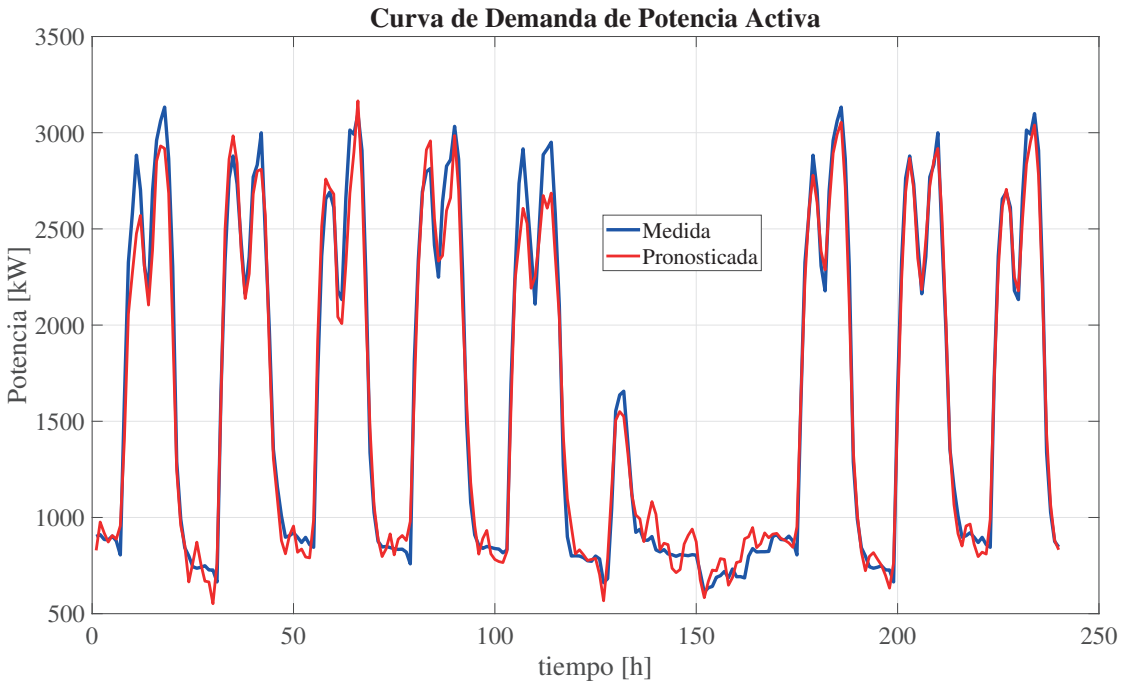

Figura 3.5: Comparación de perfiles de demanda: medidos - pronosticados

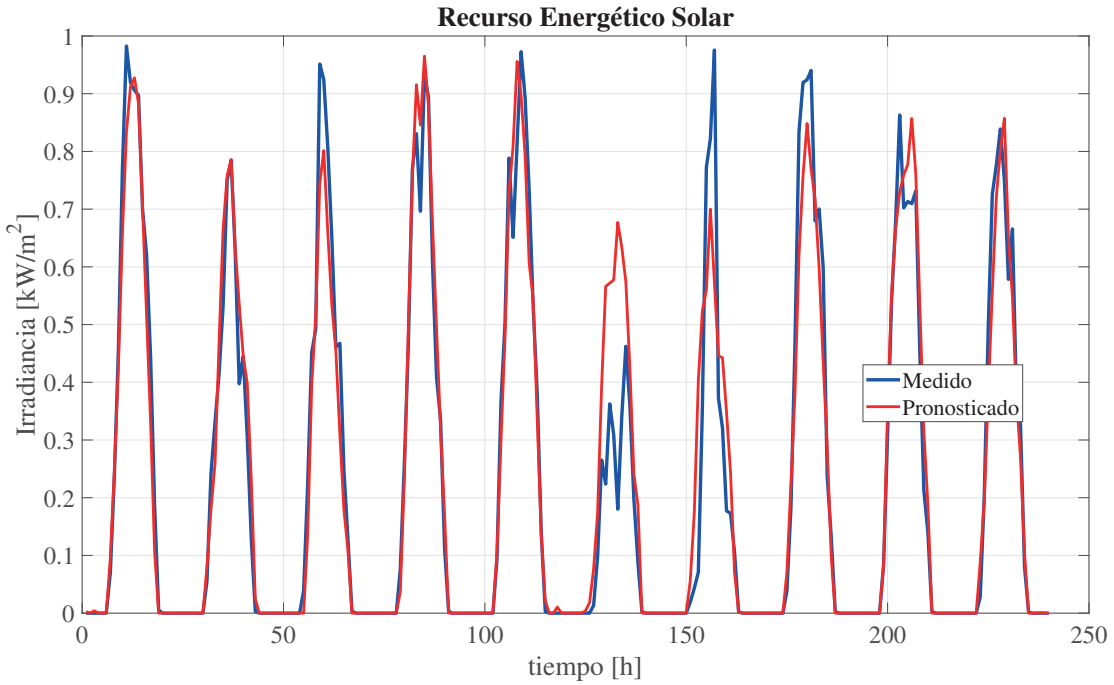

Figura 3.6: Comparación de perfiles de irradiancia: medidos - pronosticados

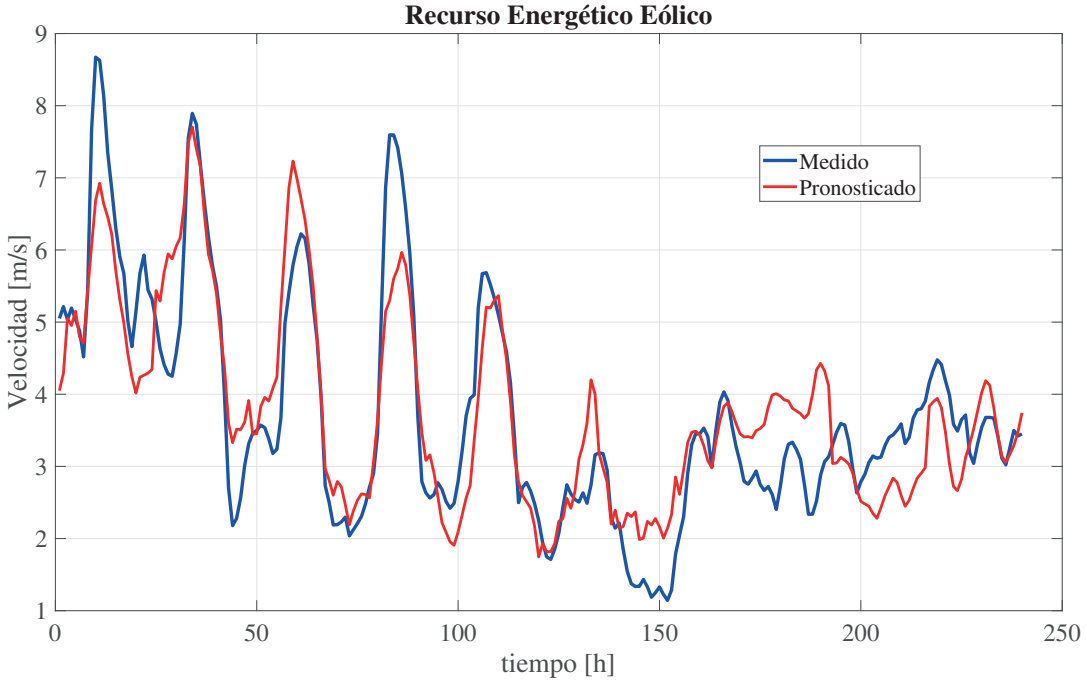

Figura 3.7: Comparación de perfiles de velocidad del viento: medidos - pronosticados

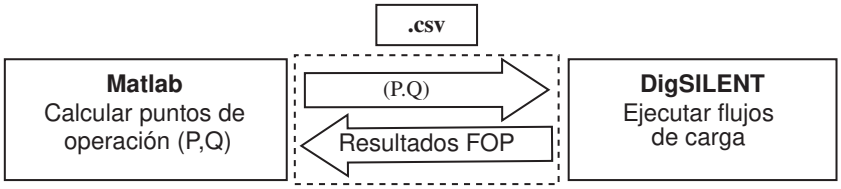

Figura 3.8: Diagrama de co-simulación

para mejorar la disponibilidad del servicio y conseguir el balance de potencia en cada instante de tiempo. En el escenario propuesto en la Subsección 3.3.7, si no se emplea MPC, no se logra abastecer la demanda en los picos de consumo, como se detalla en la Figura 3.9. En esta figura se compara el balance de potencia activa y reactiva en diez días de gestión al emplear dos estrategias de control: modelo no lineal solucionado con el algoritmo secuencial de manera no predictiva ($H_p = 1$) y de manera predictiva con $H_p = 24$. El método no predictivo presenta un error en demanda del $12.25\,\%$ en potencia activa y $11.73\,\%$ en potencia reactiva, mientras que, al incorporar un horizonte de predicción se logra reducir los errores en demanda prácticamente a cero.

La Figura 3.10 muestra las curvas de despacho de potencia activa, donde se evidencia que, al aplicar MPC, la dinámica del generador diésel (G1) cambia, mientras que el generador solar (G2) y el generador eólico (G3) siempre se despachan a su máxima capacidad, de

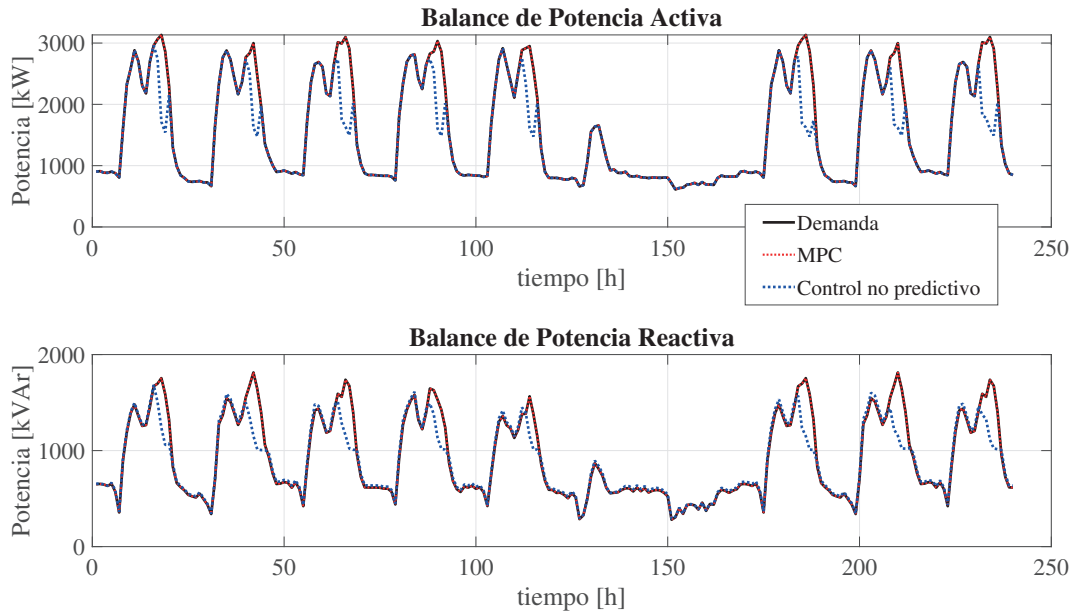

Figura 3.9: Comparación del balance de potencia activa y reactiva: Control no predictivo - MPC

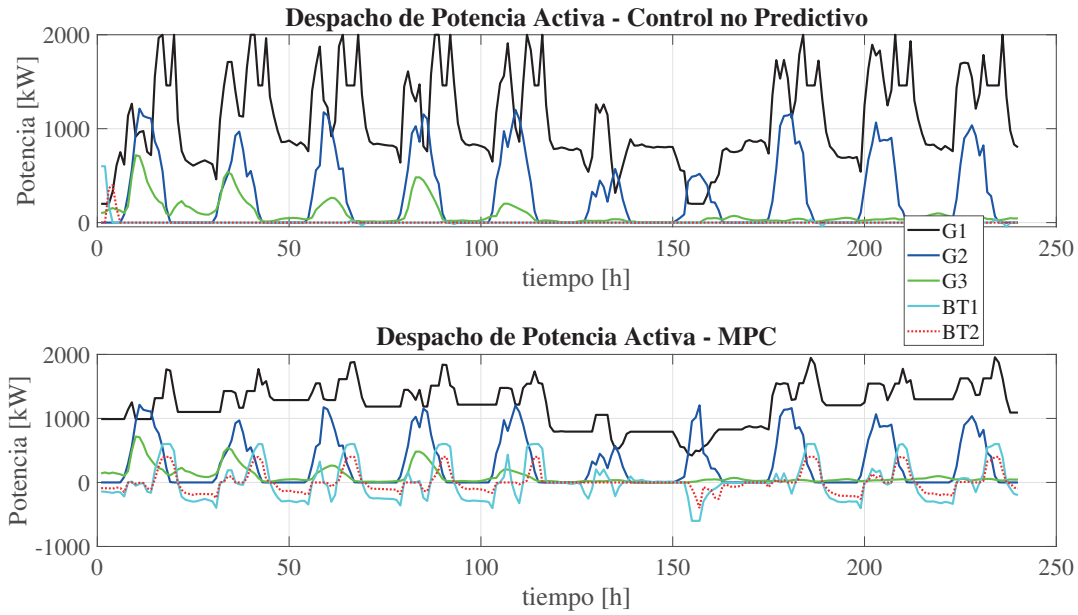

Figura 3.10: Comparación de perfiles de despacho de potencia activa: Control no predictivo - MPC

acuerdo con la disponibilidad de recursos presentada en la Figura 3.4. Lo anterior, se debe a que al considerar un horizonte de predicción, el generador diésel carga las baterías en los instantes de bajo consumo para compensar eventos futuros como picos de consumo o caídas en la generación. Por otro lado, al no considerar un horizonte de predicción, el despacho solo cumple el objetivo de abastecer la demanda actual, por lo que las baterías no se gestionan, como lo detalla la Figura 3.11, en donde se compara los estados de carga de las UAs en los dos métodos. Como consecuencia, en los diez días de gestión, cuando se aplica control predictivo, el costo por generación incrementa $16\,\%$ debido a que el generador diésel aumenta su participación $9.96\,\%$, la unidad de almacenamiento BT1 $94.09\,\%$ y BT2 $92.8\,\%$. El costo total en cada instante de gestión para las dos técnicas de control se presenta en la Figura 3.12.

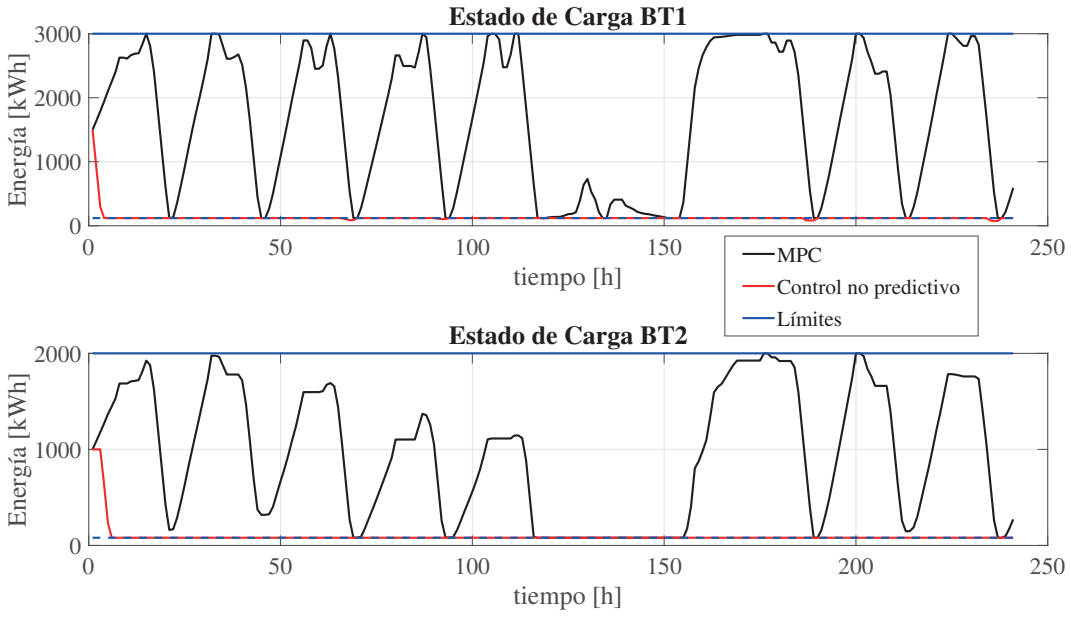

Figura 3.11: Comparación del estado de carga de las unidades de almacenamiento: Control no predictivo - MPC

La Figura 3.13 evidencia la influencia del MPC en el despacho de potencia reactiva. Los perfiles muestran cómo al aplicar MPC, gran parte de la demanda se suple por las baterías y la participación de los generadores diésel (G1) y fotovoltaico (G2) disminuye considerablemente. El hecho de que las UAs puedan despachar potencia reactiva permite corregir los perfiles de tensión de los nodos, como se detalla en la Figura 3.14. Esta última compara las magnitudes de voltaje en tres escenarios: cuando se gestión solo la potencia activa con control no predictivo, cuando se realiza despacho de potencia activa y reactiva con control no predictivo, y cuando se emplea MPC tanto para la gestión de la potencia activa como para la reactiva. Los resultados indican que la gestión de la potencia reactiva corrige la desviación de voltaje dentro del intervalo permitido del $5\,\%$, y que al aplicar

MPC se consigue una mejor corrección.

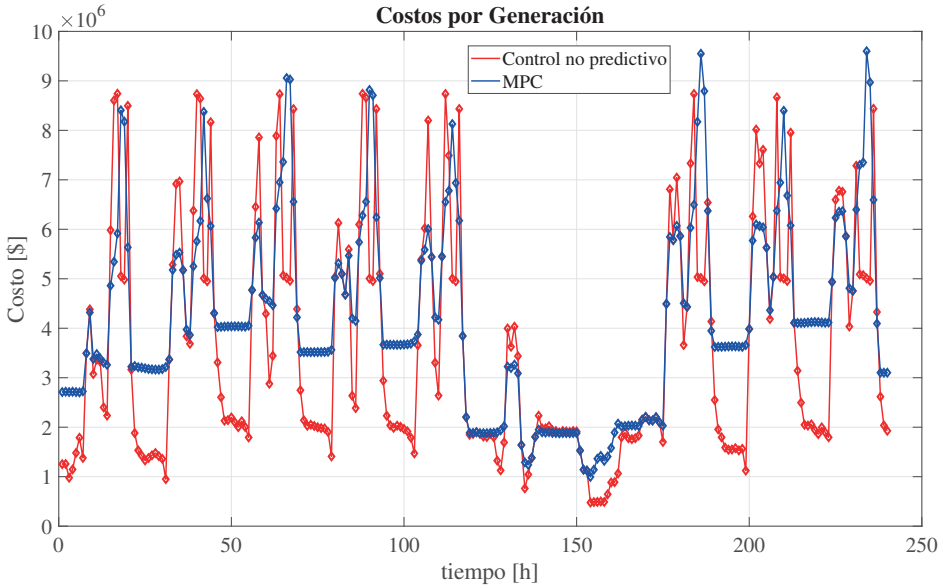

Figura 3.12: Comparación de costos por generación: Control no predictivo - MPC

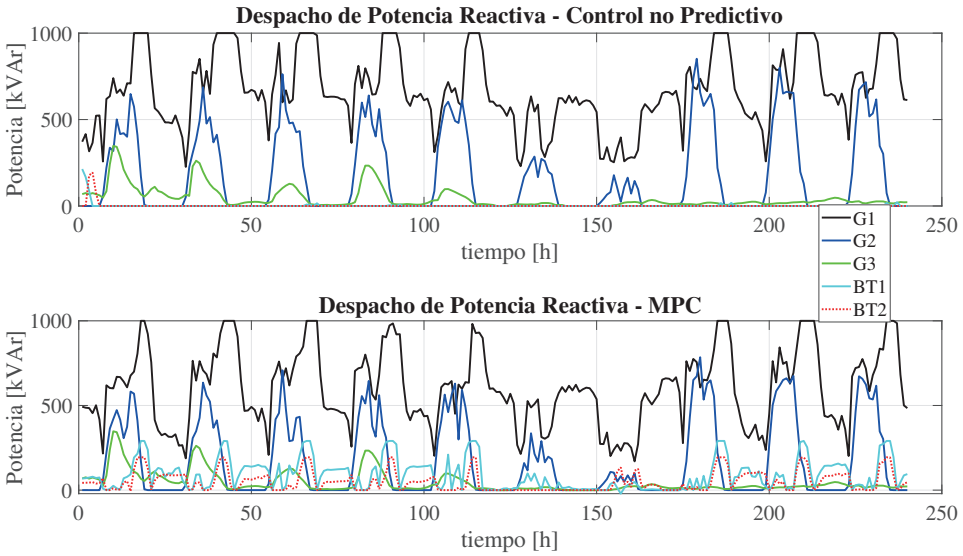

Figura 3.13: Comparación de perfiles de despacho de potencia reactiva: Control no predictivo - MPC

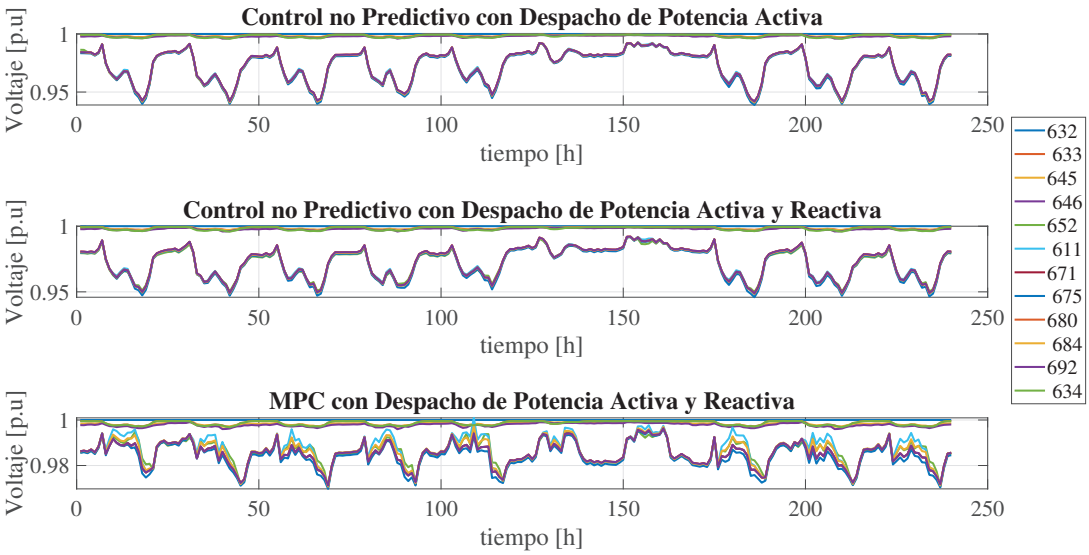

Figura 3.14: Comparación de voltajes de nodo: Control no predictivo - MPC

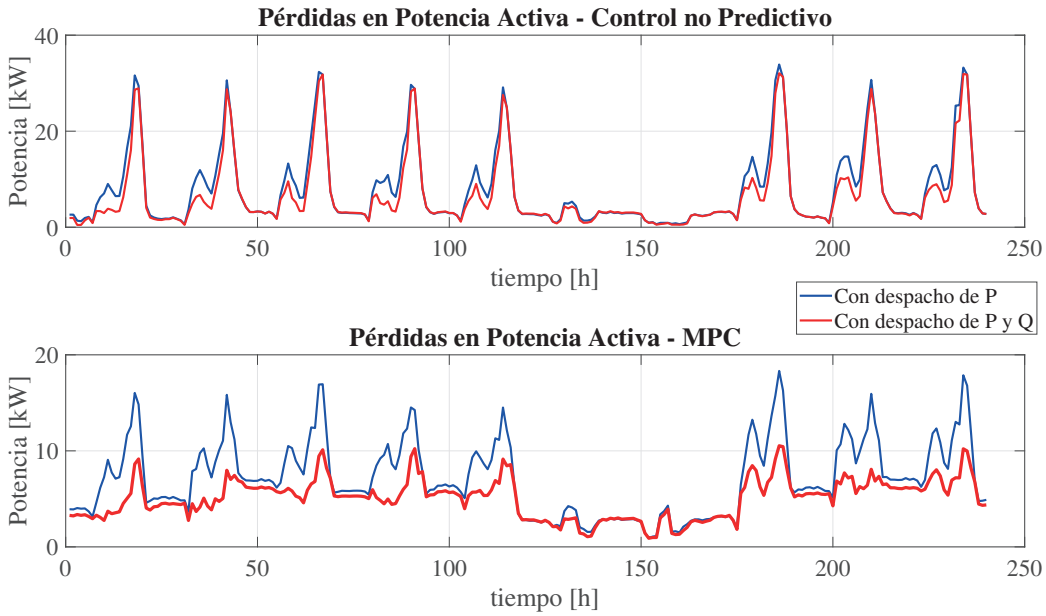

Figura 3.15: Comparación de pérdidas en potencia activa: Control no predictivo - MPC

El beneficio de la corrección de los perfiles de tensión se evidencia en la Figura 3.15, en donde se muestran las pérdidas en potencia activa. Las curvas permiten apreciar que al aplicar MPC y realizar despacho conjunto de potencia activa y reactiva, se consigue disminuir las pérdidas en el sistema. Incluir el despacho de potencia reactiva en la gestión no predictiva disminuye las pérdidas un $15.19\,\%$, la gestión predictiva con despacho de potencia activa un $10.6\,\%$ y la gestión predictiva con despacho conjunto de potencia activa y reactiva un $33.83\,\%$.

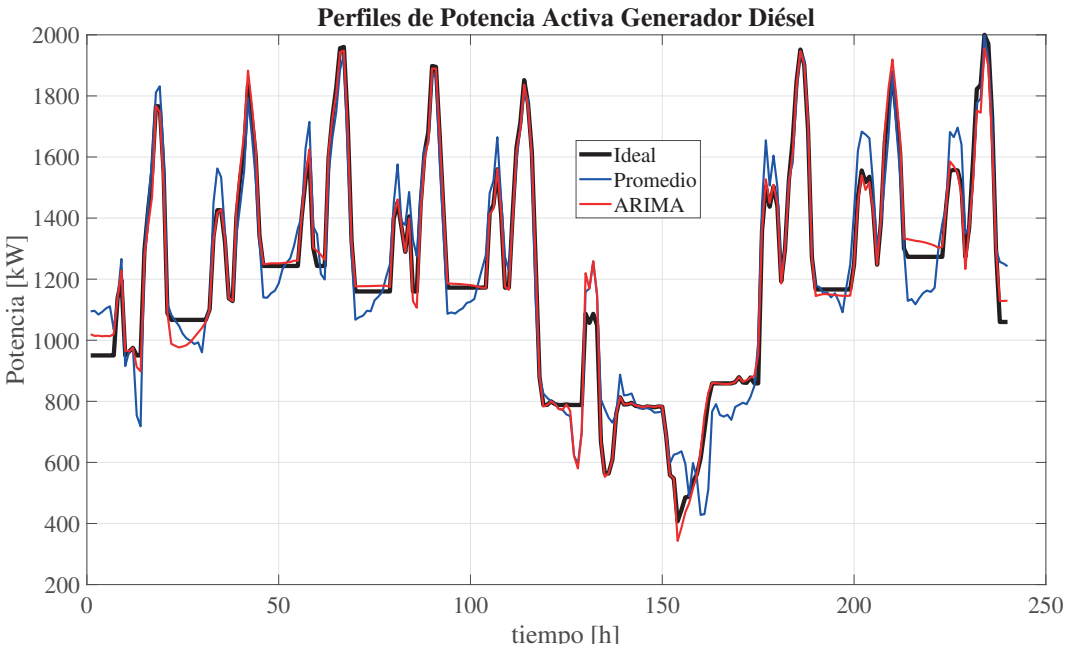

Figura 3.16: Comparación de perfiles de despacho de potencia activa del generador diésel: MPC con horizonte de predicción ideal - MPC con estimación de demanda y generación a partir del promedio de datos anteriores - MPC incorporando modelos de predicción

3.3.9.2 Incorporación de modelos de predicción: Para analizar la importancia de incorporar modelos de predicción en la gestión energética de microrredes, se comparan los resultados obtenidos al resolver el problema de despacho no lineal con el algoritmo secuencial, y definiendo $H_p = 24$ en tres escenarios: i) considerando un horizonte de predicción ideal, ii) estimando demanda y generación como el promedio de los tres días anteriores, iii) incorporando los modelos de predicción de la Subsección 3.3.8. Para el pronóstico de la demanda a partir del promedio, las curvas de consumo de los días de la semana se estiman como el promedio de los tres días anteriores, pero excluyendo sábados y domingos. De igual manera, el pronóstico de demanda para los fines de semana se realiza excluyendo los días entre semana, de tal forma que las predicciones correspondientes a los días sábados y domingos dependen del consumo de los tres fines de semana anteriores.

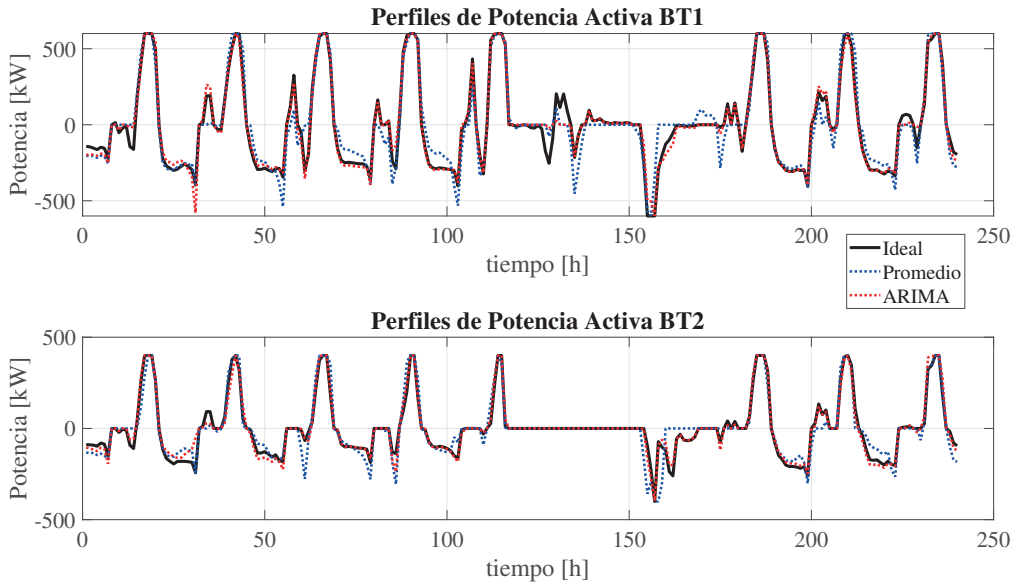

Figura 3.17: Comparación de perfiles de despacho de las unidades de almacenamiento: Horizonte de predicción ideal - Estimación promedio - Modelos ARIMA

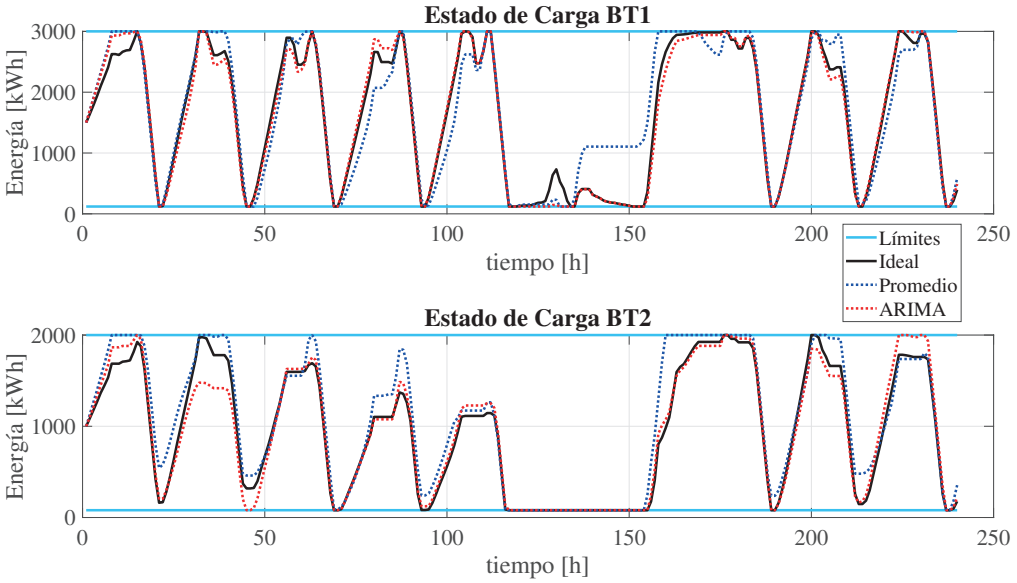

Figura 3.18: Comparación del estado de carga de las unidades de almacenamiento: Horizonte de predicción ideal - Estimación promedio - Modelos ARIMA

Los perfiles de despacho en potencia activa de los generadores renovables no se ven afectados debido a que se despachan a su máxima capacidad. Sin embargo, las dinámicas de generación del generador diésel y las UAs cambian para afrontar errores de predicción en los horizontes. Lo anterior se muestra en las Figuras 3.16, 3.17 y 3.18, donde se comparan los perfiles de despacho de potencia activa y el estado de carga de las unidades de almacenamiento. En ellas se evidencia cómo la estimación promedio desvía los puntos de de operación y cómo la incorporación de modelos de predicción los aproxima a los óptimos, determinados al considerar un horizonte ideal.

Resultados similares ocurren en el despacho de potencia reactiva para el generador diésel, el fotovoltaico y las UAs, como se detalla en las Figuras 3.19 y 3.20, mientras que el generador eólico no se ve afectado. Luego, se observa en la Figura 3.21, que tanto los costos como las pérdidas varían con las desviaciones de los puntos de operación. En los diez días de gestión, cuando se pronostica la generación renovable y la demanda, el promedio de días anteriores tiene un incremento del $0.6\,\%$ en costos y del $0.93\,\%$ en pérdidas, mientras que al incorporar los modelos de predicción, los costos solo aumentan el $0.2\,\%$ y las pérdidas el $0.42\,\%$, con relación a los obtenidos con el horizonte ideal.

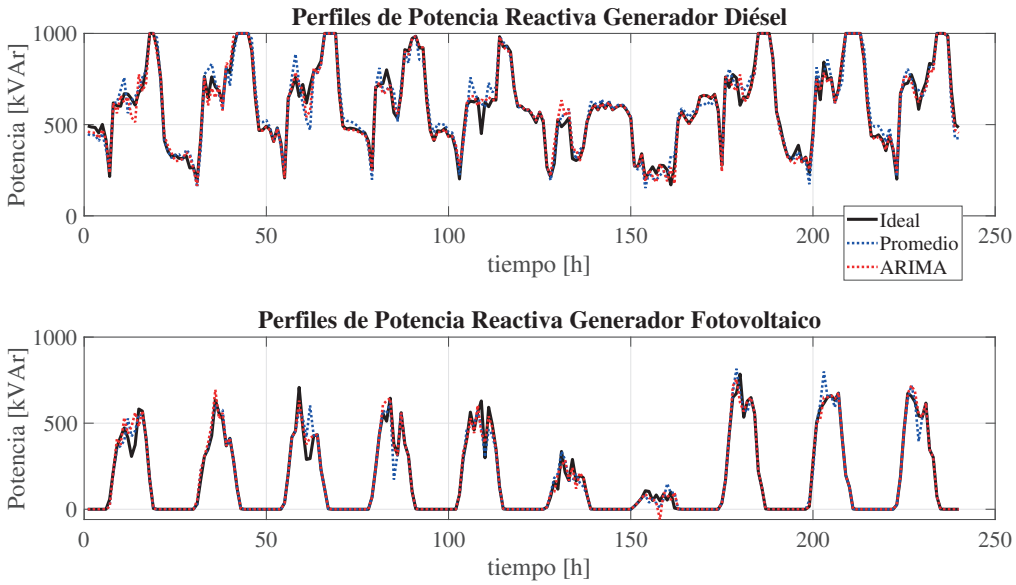

Figura 3.19: Comparación de los perfiles de despacho de potencia reactiva de los generadores diésel y fotovoltaico obtenidos al evaluar el algoritmo MPC con: estimación ideal, estimación a partir del promedio de datos anteriores y estimación con modelos de predicción

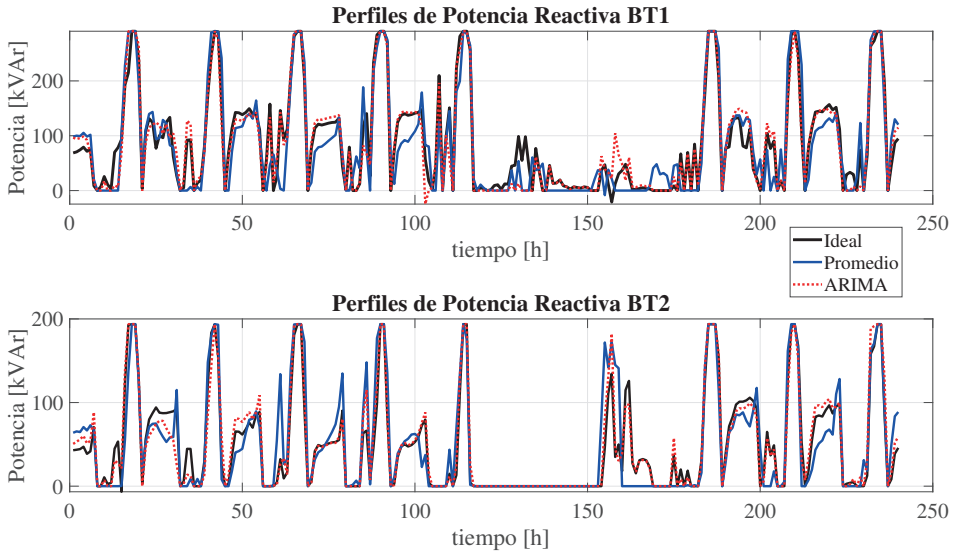

Figura 3.20: Comparación de los perfiles de despacho de potencia reactiva de las unidades de almacenamiento al emplear MPC con: estimación ideal, estimación a partir del promedio de datos anteriores y estimación con modelos de predicción

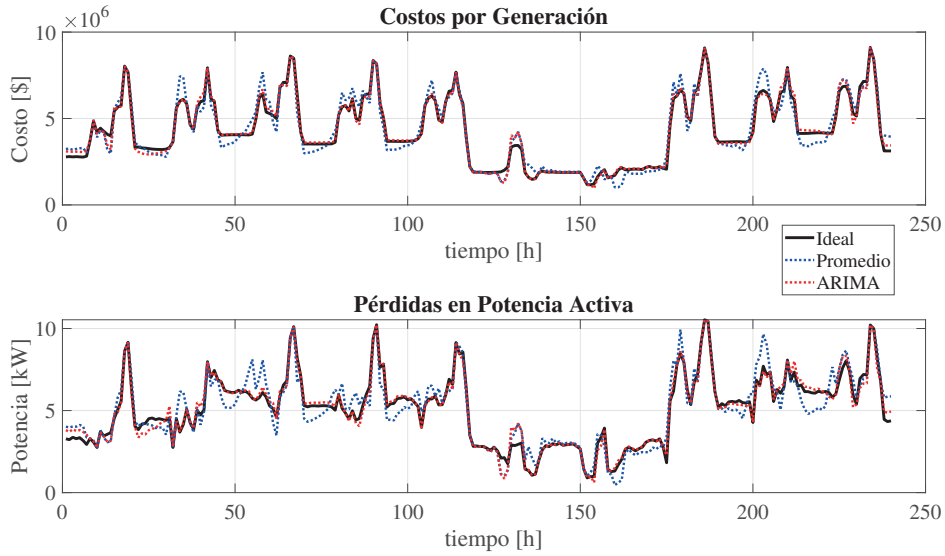

Figura 3.21: Comparación de costos por generación y pérdidas de potencia activa en 3 escenarios de control: MPC con horizonte de predicción ideal, MPC con estimación de demanda y generación a partir del promedio de datos anteriores y MPC incorporando modelos de predicción

3.3.9.3 Linealizaciones: Generalmente, los problemas no convexos empleados en la gestión energética de microrredes deben adaptarse para la implementación real. Para ello, es conveniente formular modelos que garanticen la convergencia de los algoritmos y óptimos globales, por lo tanto, las simplificaciones en las ecuaciones deben considerar la relación entre precisión y convexidad [87]. Las linealizaciones determinadas por las ecuaciones (3.29), (3.30) y (3.40) permiten simplificar considerablemete los modelos real y fasorial formulados para el despacho de potencia reactiva, manteniendo una buena representación de las ecuaciones del flujo de carga. Lo anterior, se evidencia en la Figura 3.22, donde se grafican las tensiones de nodo obtenidas al resolver el problema de despacho mediante MPC secuencial, con un horizonte $H_p = 24$h y empleando las restricciones del flujo de carga no lineales y linealizadas.

Los puntos de operación en potencia reactiva se comparan en las Figuras 3.23 y 3.24. El hecho de que las linealizaciones suavicen las restricciones de flujo de carga hace que los generadores disminuyan su participación, y que las unidades de almacenamiento entreguen más potencia, especialmente en los picos de mayor consumo. Lo anterior se ve reflejado en la Figura 3.25, donde se grafican las pérdidas medidas en DigSILENT® al evaluar los puntos de operación encontrados cuando se consideran las restricciones del flujo de

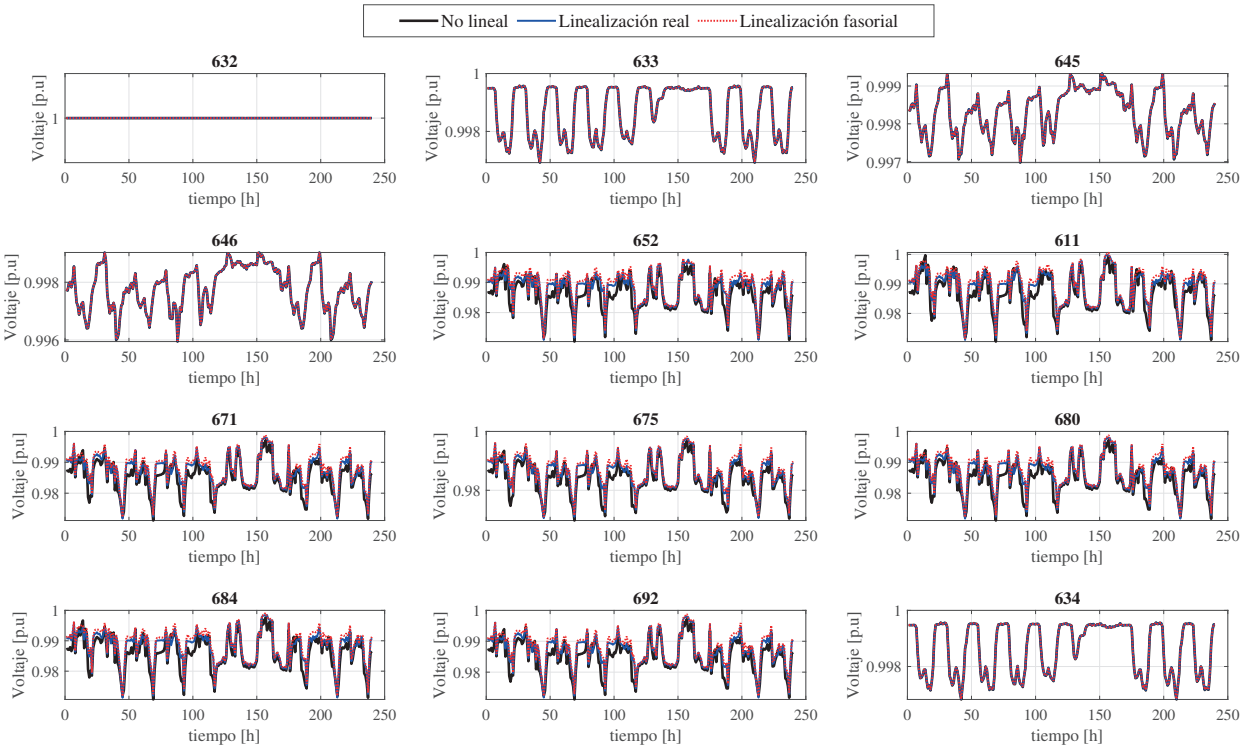

Figura 3.22: Comparación de la desviación de los voltajes de nodo: MPC con ecuaciones de flujo no lineales - MPC con ecuaciones de flujo linealizadas

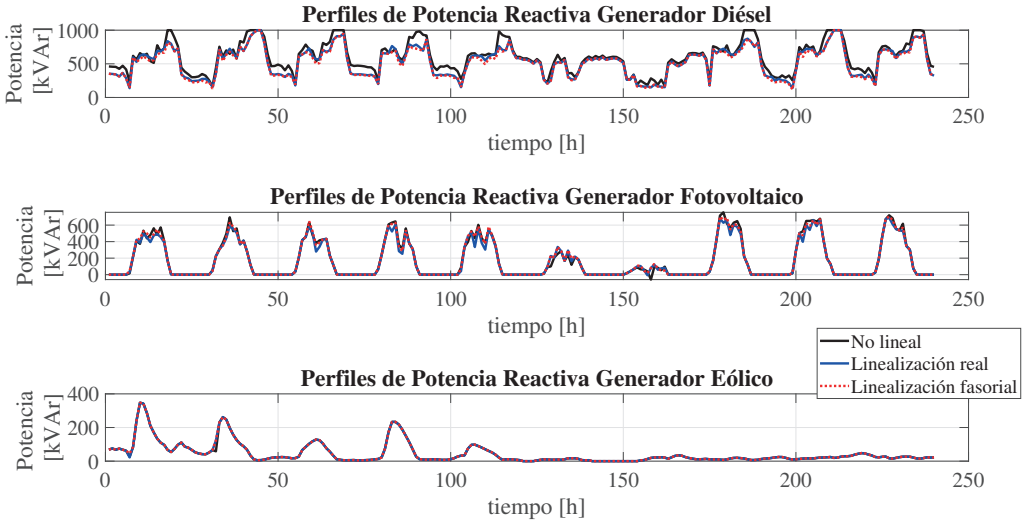

Figura 3.23: Comparación de los perfiles de despacho de potencia reactiva de los generadores diésel, fotovoltaico y eólico, al aplicar MPC con ecuaciones de flujo no lineales y con ecuaciones de flujo linealizadas

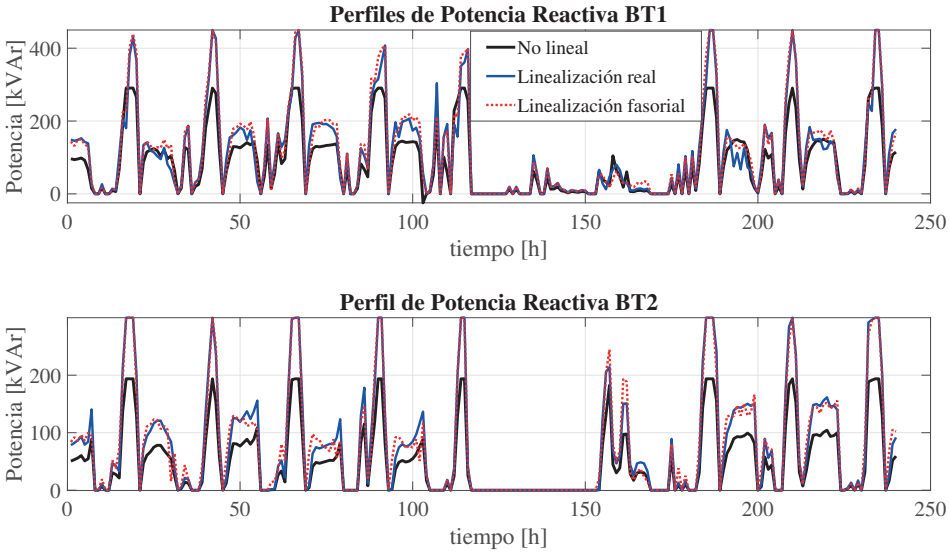

Figura 3.24: Comparación de los perfiles de despacho de potencia reactiva de las unidades de almacenamiento, al aplicar MPC con ecuaciones de flujo no lineales y con ecuaciones de flujo linealizadas

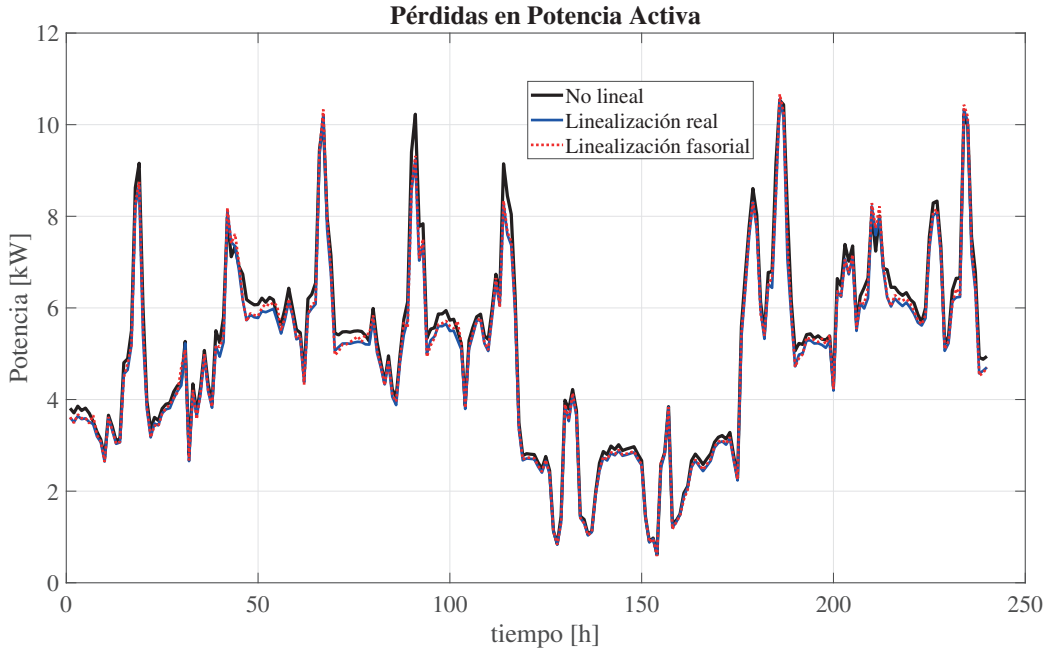

Figura 3.25: Comparación de las pérdidas en potencia activa: MPC con ecuaciones de flujo no lineales - MPC con ecuaciones de flujo linealizadas

carga no lineales y linealizadas. La diferencia entre las pérdidas generadas al incorporar la linealización real y la fasorial son mínimas, pero con relación a las que genera el modelo no lineal, se tiene que en los diez días de gestión se reducen en promedio el $4.25\,\%$. Esto permite concluir que el modelo no lineal converge a un óptimo local y que los puntos de operación en potencia reactiva mejoran con las linealizaciones.

3.3.9.4 MPC centralizado unificado: Cuando se resuelven los problemas de despacho de manera secuencial, existe la posibilidad de que los puntos de operación en potencia activa generen desviaciones de voltaje que no se puedan corregir con el despacho reactivo, afectando la convergencia del Algoritmo 3.1. Por lo tanto, la principal ventaja de emplear los modelos unificados radica en encontrar puntos de operación dentro de las condiciones físicas y técnicas de la microrred y garantizar la convergencia del Algoritmo 3.2.

Cuando se emplea el modelo unificado, los parámetros α y β son de gran importancia, puesto que determinan el grado de relevancia de los costos y las pérdidas en la función objetivo. Generalmente, se prioriza la minimización de costos, sin embargo, en el modelo propuesto, fijar $\beta > \alpha$ implica que en el instante de tiempo actual t_o se priorice la minimización de las pérdidas, mas no en todo el horizonte de gestión. Lo anterior se debe a que el problema para el despacho reactivo no está definido en H_p, dado que no tiene relación directa con las UAs, sino con el inversor asociado a ellas.

En la Figura 3.26 se compara los perfiles de despacho en potencia activa del generador diésel y las unidades de almacenamiento encontrados mediante el algoritmo secuencial

con aquellos obtenidos con el algoritmo unificado, al fijar $H_p = 24$, $\alpha = 10$ y $\beta = 1$. La potencia entregada por el generador diésel disminuye en los tiempos de bajo consumo e incrementa en los picos de demanda. En consecuencia, las UAs disminuyen su participación, como se evidencia en la Figura 3.27, donde se comparan los estados de carga de las baterías obtenidos con los dos algoritmos.

Los generadores renovables siempre despachan potencia activa a su máxima capacidad, pero el despacho de potencia reactiva sí cambia con los métodos de gestión. Lo anterior se evidencia en la Figura 3.28, la cual muestra los perfiles de despacho de los generadores diésel, fotovoltaico y eólico encontrados de manera secuencial y unificada. La potencia reactiva entregada por los generadores diésel y fotovoltaico incrementa cuando se emplea el algoritmo unificado, tanto con el modelo real como con el modelo fasorial, mientras que la participación del generador eólico disminuye ligeramente cuando se emplea el algoritmo unificado con el modelo fasorial. Por su parte, los perfiles de potencia reactiva en las UAs, graficados en la Figura 3.29, muestran que al emplear el algoritmo unificado su participación disminuye y que las dinámicas cambian dependiendo del modelo empleado.

En el escenario propuesto, tanto el algoritmo secuencial como el unificado eliminan el error en demanda cuando se considera un horizonte de predicción. Sin embargo, las variaciones en los perfiles de generación se reflejan en los costos y la potencia que se pierde en la distribución. La Figura 3.30 compara los costos y las pérdidas que generan los perfiles de despacho encontrados con el algoritmo secuencial, con aquellos que generan los

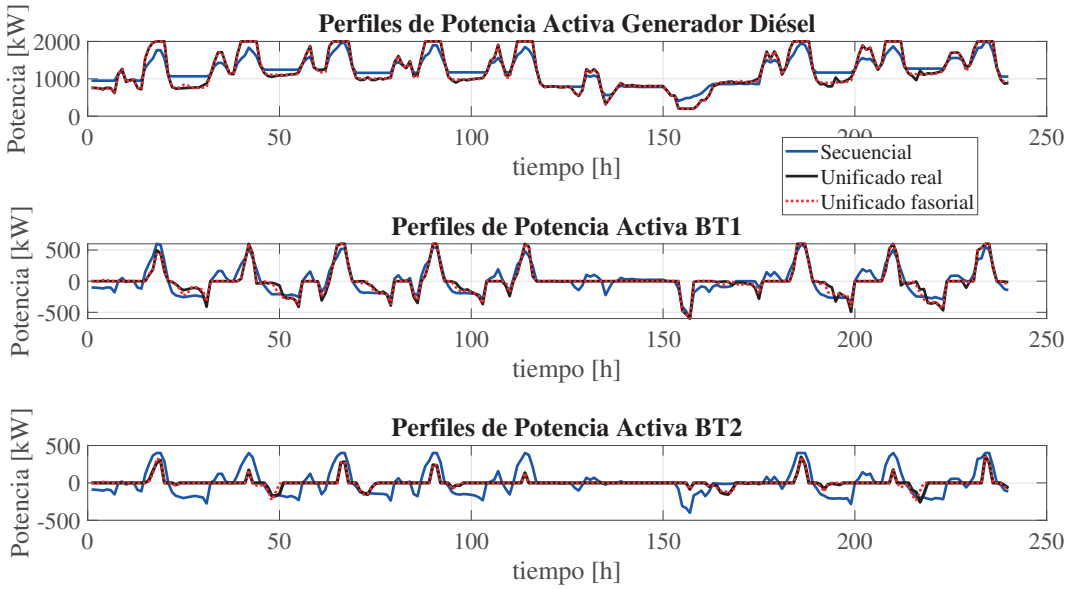

Figura 3.26: Comparación de los perfiles de generación de potencia activa del generador diésel (G1) y las UAs (BT1 y BT2): algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial

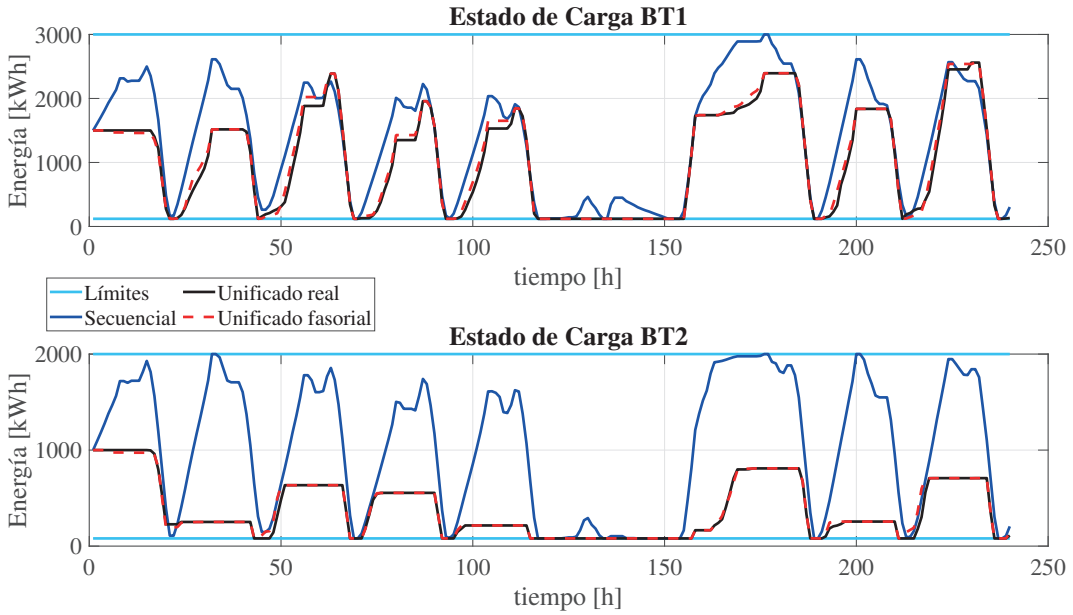

Figura 3.27: Comparación de los estados de carga de las UAs: algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial

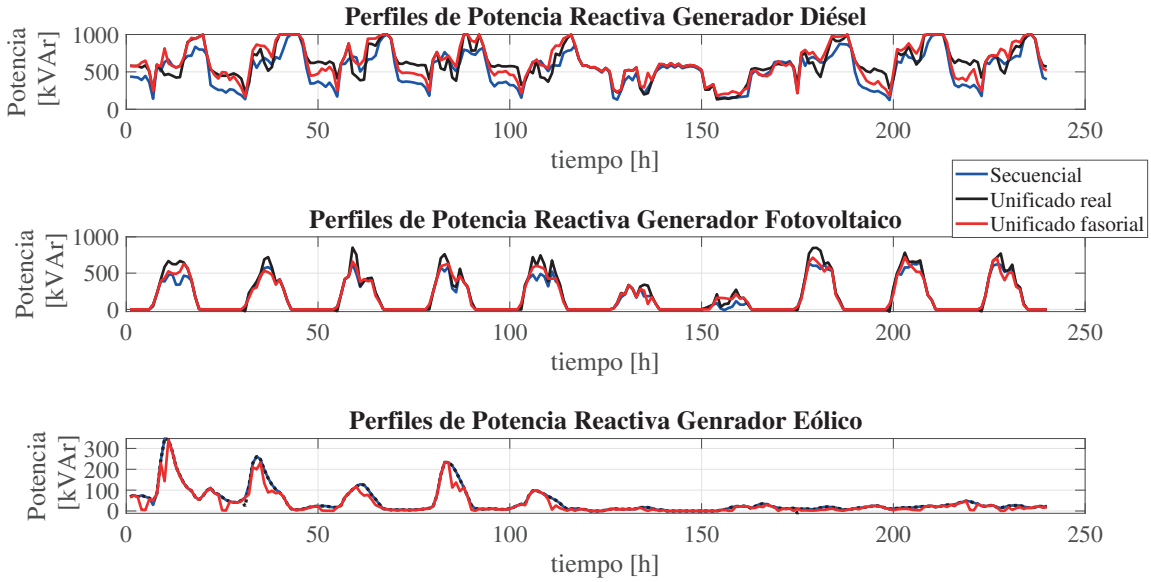

Figura 3.28: Comparación de los perfiles de generación en potencia reactiva de los generadores diésel (G1), fotovoltaico (G2) y eólico(G3): algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial

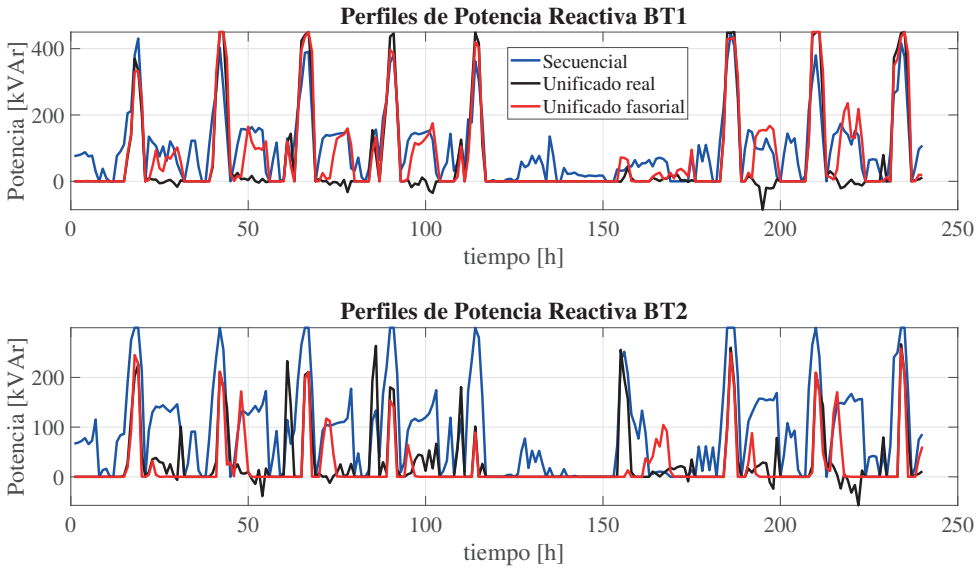

Figura 3.29: Comparación de los perfiles de generación de potencia reactiva de las UAs: algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial

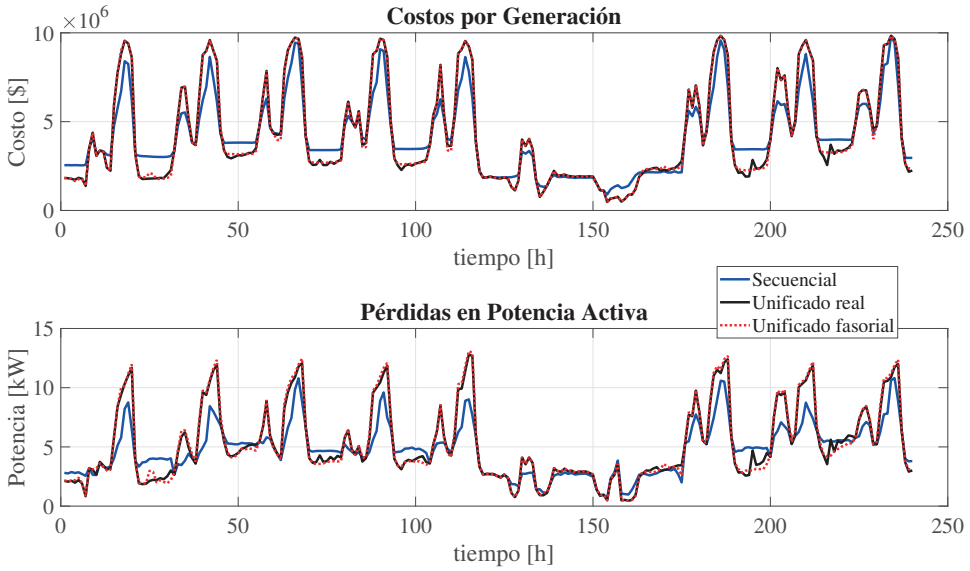

Figura 3.30: Comparación de las pérdidas y los costos por generación: algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial

perfiles de despacho encontrados con el algoritmo unificado, empleando los dos modelos (real y fasorial). Cuando el despacho se realiza con el algoritmo unificado, los costos y las pérdidas disminuyen en los periodos de baja demanda, con relación a los datos asociados al algoritmo secuencial. Lo anterior tiene relación directa con la gestión de las UAs, puesto que el algoritmo unificado limita la carga de las baterías en los periodos de bajo consumo, minimizando costos y pérdidas en esos instantes de tiempo. Sin embargo, como consecuencia, se reduce la capacidad para entregar potencia activa y reactiva en la UAs, lo que incrementa tanto los costos como las pérdidas cuando se presentan picos de demanda.

Luego, si se analiza los costos acumulados y las pérdidas totales, se concluye que, cuando $\alpha > \beta$ los perfiles de despacho se aproximan más a los óptimos encontrados con el algoritmo secuencial, como se muestra en la Tabla 3.4. Por otro lado, cuando se establece $\beta > \alpha$, tanto el costo como las pérdidas incrementan debido a que entre mayor sea β y menor sea α, menor será la participación de las UAs.

Tabla 3.4: Costo acumulado y pérdidas totales en diez días de gestión

Algoritmo	Secuencial		Unificado			
Modelo	Real	Fasorial	Real	Fasorial	α	β
Costo [$]	9,996e8	9,996e8	1.0216e9	1.0217e9	10	1
			1.019e9	1.020e9	1	0
			1.042e9	1.025e9	1	1
			1.051e9	1.033e9	1	10
Pérdidas [kW]	1.149e3	1.151e3	1.255e3	1.263e3	10	1
			1.275e3	1.278e3	1	0
			1.266e3	1.271e3	1	1
			1.281e3	1.303e3	1	10

Los tiempos de convergencia se comparan en la Tabla 3.5. En un procesador *Intel Core* i5 de seis núcleos, los dos algoritmos convergen en tiempos del orden de segundos. Aunque *cvx* tarda más en converger, estos tiempos son validos para le gestión de microrredes a nivel terciario, puesto que, como se mencionó anteriormente, los despachos de potencia demandan tiempos de gestión relativamente largos (del orden de minutos u horas).

Los resultados presentados en esta sección, permiten concluir que el algoritmo secuencial consigue mejores óptimos que el unificado y que esos óptimos mejoran cuando se incorporan modelos de predicción y se suavizan las restricciones con las linealizaciones de las ecuaciones del flujo de potencia. Sin embargo, el hecho de resolver los problemas de despacho por separado no garantiza la convergencia del Algoritmo 3.1, mientras que, los modelos unificados sí garantizan la convergencia del Algoritmo 3.2. Por otro lado, se

Tabla 3.5: Tiempo promedio de convergencia de los algoritmos centralizados

Algoritmo	Secuencial		Unificado	
Solver	fmincon	cvx	fmincon	cvx
Tiempo [s]	2.086	12.911	0.2185	1.028

observa que los dos modelos (real y fasorial) convergen a óptimos similares, tanto cuando se emplea el algoritmo secuencial como cuando se emplea el unificado. Lo anterior, permite afirmar que los dos modelos son eficientes para la optimización predictiva de la microrred.

3.4 MPC distribuido para el despacho óptimo de potencia activa

La ventaja de emplear algoritmos distribuidos en la gestión energética de microrredes radica en la posibilidad de separar el problema en subproblemas y solucionarlos de forma independiente, pero encontrando soluciones óptimas globales. A pesar de que estos algoritmos presentan tiempos de convergencia más elevados que los métodos centralizados, siguen siendo eficientes para solucionar problemas de despacho, puesto que el control terciario en microrredes presenta tiempos de control relativamente elevados (minutos - horas). Por consiguiente, estas estrategias de gestión son útiles para la conformación de microrredes mediante la integración de sistemas energéticos, en donde cada GD cuenta con su propio controlador, como se detalla en la Figura 3.31.

En esta sección se propone emplear el algoritmo de *consensus*, aplicando el mismo razonamiento del método ADMM detallado en [82], [100] para la distribución del problema presentado en la Subsección 3.3.2 para el despacho de potencia activa.

Para ello, primero es necesario separar la función de costos del problema, la cual se puede reescribir como:

$$C_{MPC} = \sum_{i=1}^{N_g+N_b} C_{MPCi}, \tag{3.48}$$

donde C_{MPC_i} corresponde a la función de costos relacionada al i-ésimo GD o UA, definida en el horizonte de tiempo H_p como:

$$C_{MPCi}\left(p_{it}\right) = \sum_{t=1}^{H_p} \left(p_{it}^2 + b_i p_{it} + c_i\right), \tag{3.49}$$

donde, para las unidades de almacenamiento, la variable p corresponde a la potencia de descarga y los coeficientes son $a_i = 0$, $c_i = 0$ y b_i se establece a partir de la Ecuación (3.3).

El método de *consensus* se basa en definir las restricciones globales como restricciones de consenso [82]. En el problema de despacho establecido en la Subsección 3.3.2, las

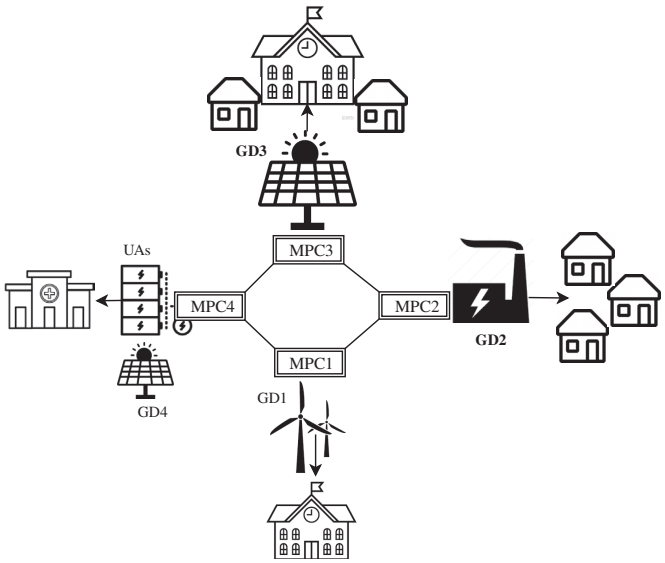

Figura 3.31: Gestión distribuida de microrredes conformadas por sistemas energéticos independientes

restricciones de límites (3.15), (3.16), (3.17), (3.18) y (3.19) son propias de cada GD o UA. Por lo tanto, la única restricción global es (3.14), que establece el balance de potencia activa en todo el sistema. Luego, dado que (3.14) es lineal y el problema en general es convexo, es posible emplear el algoritmo ADMM detallado en [99], [100], [116] para construir una función objetivo independiente para cada GD o UA de la microrred.

El algoritmo ADMM se basa en el cálculo del *lagrangiano aumentado*, el cual se establece a partir de (3.48) y (3.14) como:

$$L_i(p_{it}) = \sum_{t=1}^{H_p} \left(C_{MPC_t} + \lambda_t \left(\left(\sum_{i=1}^{N_s} p_{it} \right) - p_t^L - p_t^{\text{loss}} \right) + \frac{u}{2} \left\| \left(\sum_{i=1}^{N_s} p_{it} \right) - p_t^L - p_t^{\text{loss}} \right\|^2 \right), \tag{3.50}$$

donde N_s corresponde al número de sistemas de generación con control independiente, $u > 0$ es el factor de sintonización y λ_t es el multiplicador de Lagrange en el instante de tiempo t. Luego, el lagrangiano correspondiente a cada generador se obtiene considerando constante la potencia de los demás GDs y UAs. Reemplazando (3.49) y eliminando términos independientes, el lagrangiano correspondiente al sistema de generación i es

$$L_i\left(p_{it}\right) = \sum_{t=1}^{H_p} \left(\left(a_i + \frac{u}{2} \right) p_{it}^2 + \left(b_i + \lambda_t + u \Delta D_{it} \right) p_{it} \right), \tag{3.51}$$

donde

$$\Delta D_{it} = \left(\sum_{i=1}^{N_z} p_{it} \right) - \left(p_t^L + p_t^{\text{loss}} \right); \ \forall t \in \{1, \cdots, H_p\}. \tag{3.52}$$

El parámetro N_z es igual al conjunto de sistemas de generación que tiene comunicación con el controlador del i-ésimo GD.

Posteriormente, si se consideran las restricciones propias de cada GD o UA, se establecen problemas de optimización que permiten gestionar cada elemento de manera independiente, pero que en conjunto, buscan el balance de energía en todo el sistema mediante el siguiente proceso iterativo.

$$P_1^{k+1} = \underset{P_1 \in \Omega_1}{\text{argmin}} L_1(P_1, \lambda^k, \Delta D_1^k)$$

$$P_2^{k+1} = \underset{P_2 \in \Omega_2}{\text{argmin}} L_2(P_2, \lambda^k, \Delta D_2^k)$$

$$\vdots$$

$$P_{N_s}^{k+1} = \underset{P_{N_s} \in \Omega_{N_s}}{\text{argmin}} L_{N_s}(P_{N_s}, \lambda^k, \Delta D_{N_s}^k)$$

$$\lambda_t^{k+1} = \lambda_t^k + \left(\sum_{i=1}^{N_s} P_{it}^{k+1} \right) - p_t^L; \ \forall t \in \{1, \cdots, H_p\} \tag{3.53}$$

Los conjuntos Ω_i representan las soluciones factibles determinadas por las ecuaciones (3.15), (3.16), (3.17), (3.18) y (3.19) para cada subsistema de generación. P_i es el vector de H_p variables y P_i^{k+1} son las soluciones óptimas encontradas en la iteración k para todo el horizonte H. ΔD_i se actualiza en cada iteración a partir de (3.52) de la siguiente manera:

$$\Delta D_{it}^{k+1} = \left(\sum_{i=1}^{N_z} P_{it}^{k+1} \right) - \left(p_t^L + p_t^{\text{loss}} \right); \ \forall t \in \{1, \cdots, H_p\}. \tag{3.54}$$

Por último, es necesario establecer un criterio de parada que garantice que el proceso se repita hasta que se cumpla el balance de potencia en toda la microrred. Una forma de hacerlo es estableciendo un umbral para el error en demanda mediante la ecuación

$$er = \sum_{t=1}^{H_p} \left(\left(\sum_{i=1}^{N_s} P_{it}^{\text{k+1}} \right) - \left(p_t^L + p_t^{\text{loss}} \right) \right) \leq \xi, \tag{3.55}$$

donde ξ es el máximo error en demanda permitido en todo el horizonte.

El Algoritmo 3.3, resume el proceso para la implementación del método propuesto.

Algoritmo 3.3 MPC distribuido para el despacho de potencia activa

Salida: Puntos de operación (p, q) en N instantes de gestión.
$H_p \leftarrow length\,([t_0, t_1, ..., t_f])$ {Tamaño del horizonte de pronóstico}
$u \leftarrow$ constante > 0
$\lambda_t \leftarrow 0;\ \forall t \in \{1, \cdots, H_p\}$
$P_i^{admm} \leftarrow [0];\ \forall i \in \{1, \cdots, N_s\}$
$\xi \leftarrow$ Mínimo error permitido
para $n \leftarrow 1$ a N **hacer**
  $P_i^{\max} \leftarrow [P_{it_0}, P_{it1}, ..., P_{it_f}]; \forall i \in \{1, \cdots, N_g\}$ {Pronóstico de perfiles de generación renovable}
  $P^{\mathrm{L}} \leftarrow [P_{t_0}^L, P_{t1}^L, ..., P_{t_f}^L]$ {Pronóstico de la demanda total agregada}
  $er \leftarrow$ Calcular a partir de (3.55) {Establecer error inicial}
  $k \leftarrow 1$
  mientras $er > \xi$ **hacer**
    para $j \leftarrow 1$ a Ns **hacer**
      Estimar $\Delta D_j(k)$ a partir de (3.54)
      $P_j^{k+1} \leftarrow \underset{P_j \in \Omega_i}{\arg\min} L_j(P_j, \lambda(k), \Delta D_j)$
    fin para
    Calcular $\lambda(k+1)$ a partir de (3.53)
    Actualizar er a partir de (3.55)
    $k \leftarrow k+1$
  fin mientras
  $P_i^{\mathrm{opt}} = P_i^{k-1};\ \forall i \in \{1, \cdots, N_s\}$ {Potencias óptimos en todo el horizonte}
  $p_i \leftarrow P_i^{\mathrm{opt}}(t_0);\ \forall i \in \{1, \cdots, N_s\}$ {Potencias óptimas para t_0}
  $t_0 \leftarrow t_{0+1},\ t_f \leftarrow t_{f+1}$ {Horizonte de predicción para el siguiente instante de gestión}
  $n = n + 1$
fin para

3.4.1 Resultados y discusión

El algoritmo distribuido considera los enlaces de comunicación definidos por las líneas rojas en la Figura 3.32. La eficiencia del algoritmo depende del parámetro de sintonización u, como se muestra en la Figura 3.33, en donde se grafica el proceso iterativo del controlador asociado al generador diésel (G1) para llegar al óptimo, considerando diferentes valores de u. Cuando se establece $u = 0.1$, el algoritmo tarda 200 iteraciones en converger, lo que representa un tiempo aproximado de 10 minutos cuando se emplea *cvx* en un procesador *Intel Core* i5 de seis núcleos. Por otro lado, si se define $u = 1$, el algoritmo converge en solo 25 iteraciones, pero se desfasa del óptimo establecido por el método centralizado. Por consiguiente, el control se sintoniza en $u = 0.5$ para establecer una buena relación entre precisión y tiempo de convergencia.

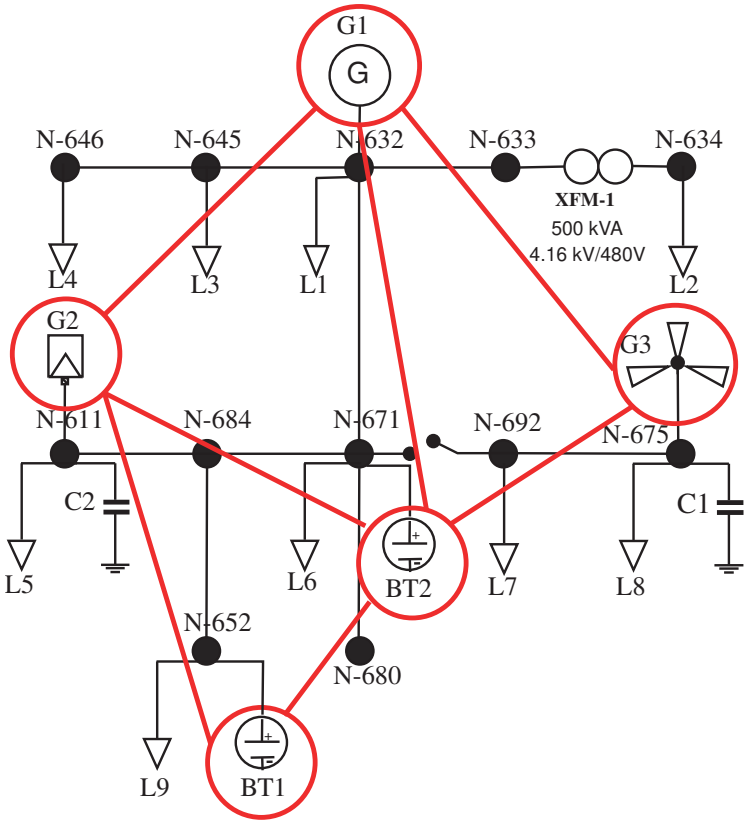

Figura 3.32: Enlaces de comunicación para la gestión distribuida

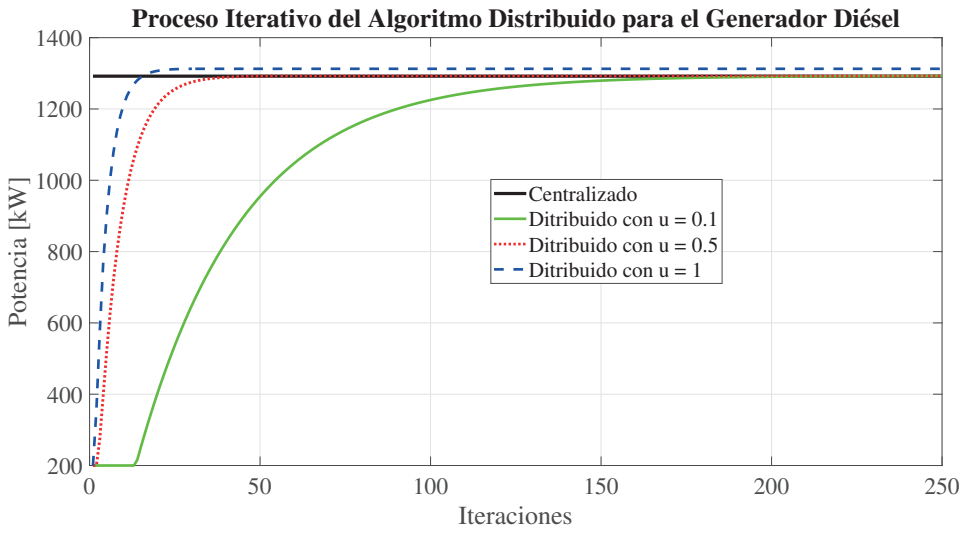

Figura 3.33: Proceso iterativo del algoritmo distribuido en el controlador del generador diésel para diferentes valores del parámetro de sintonización u

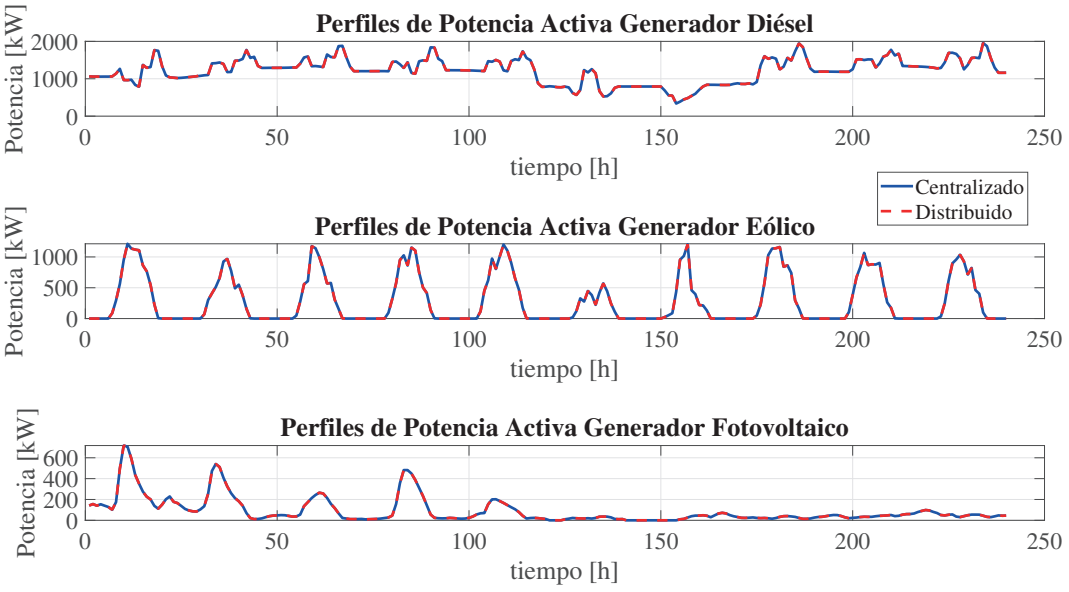

Figura 3.34: Perfiles de despacho en potencia activa de los generadores diésel (G1), fotovoltaico (G2) y eólico (G3) obtenidos con los algoritmos centralizado y distribuido

La Figura 3.34 compara los perfiles de despacho de potencia activa estimados por el algoritmo centralizado con los establecidos mediante el algoritmo distribuido para los generadores diésel, fotovoltaico y eólico. En ella se observa cómo, durante los diez días de gestión, el algoritmo distribuido consigue el mismo punto óptimo del algoritmo centralizado. Aunque se consigue una buena aproximación en las UAs, en determinados instantes de tiempo los puntos de operación tienden a alejarse de los óptimos establecidos por el algoritmo centralizado, como se detalla en las Figuras 3.35 y 3.36 que comparan los perfiles de despacho y los estados de carga de las dos unidades de almacenamiento obtenidos con las dos técnicas de control.

El algoritmo distribuido, al igual que el centralizado, garantiza el balance de potencia si se considera un horizonte de predicción suficientemente amplio. Por otro lado, las pequeñas variaciones en los puntos de operación de las UAs solo generan un incremento del $0.0003\,\%$ en el costo acumulado en los 10 días de gestión. Sin embargo, el tiempo de convergencia sí incrementa sustancialmente, como se detalla en la Tabla 3.6, en donde se muestran los tiempos cuando se emplea los solvers *fmincon* y *cvx*. En general, aunque tanto el algoritmo centralizado como el distribuido tardan más en converger cuando se emplea *cvx*, siguen siendo controles óptimos para la gestión energética en microrredes.

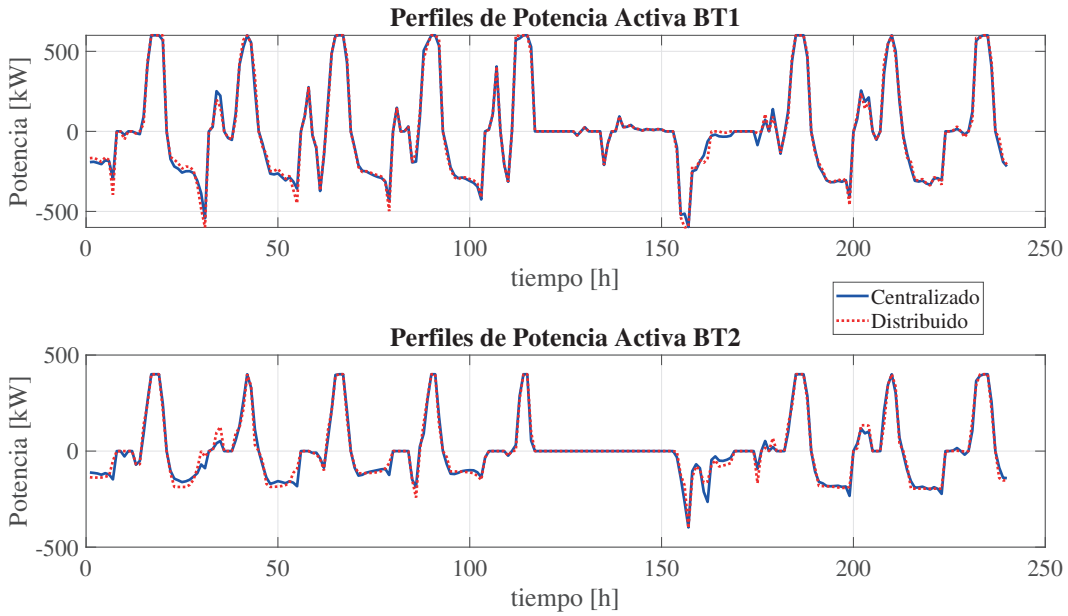

Figura 3.35: Perfiles de despacho en potencia activa de las UAs obtenidos con los algoritmos centralizado y distribuido

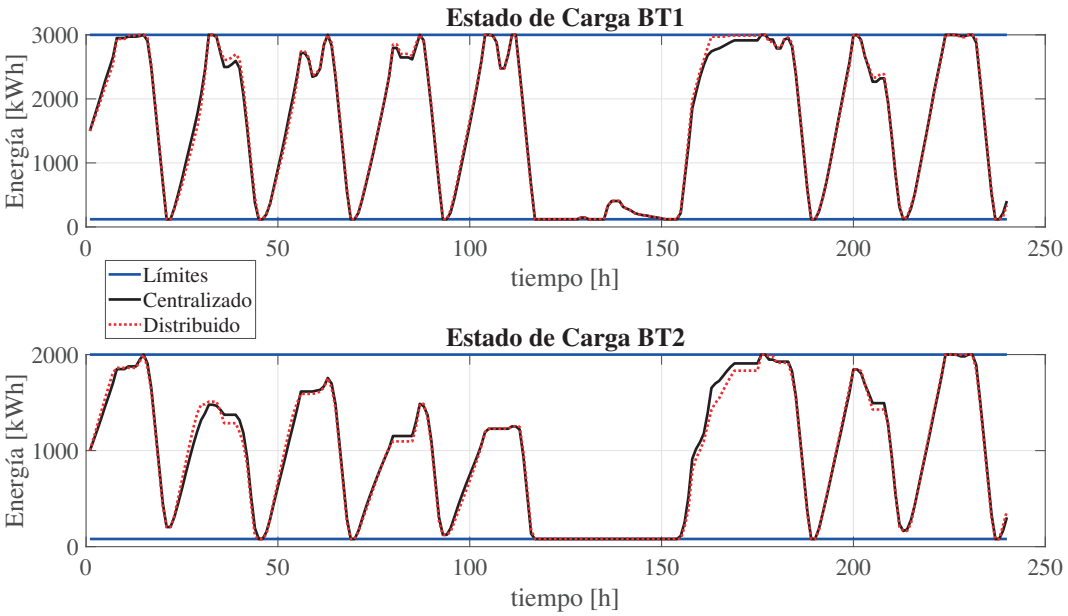

Figura 3.36: Comparación del los estados de carga de las unidades de almacenamiento obtenidos con el algoritmo distribuido con los encontrados con el algoritmo centralizado

Tabla 3.6: Tiempo promedio de convergencia

Algoritmo	Centralizado		Distribuido	
Solver	fmincon	cvx	fmincon	cvx
Tiempo [s]	0.194	0.911	63.352	176.520

3.5 Limitaciones y trabajo futuro

Las principales limitaciones del trabajo presentado en este capítulo radican en el alcance de la validación y en la metodología de predicción empleada. La validación se realizó mediante co-simulación en Matlab y DigSilent, lo que permite analizar el desempeño de la gestión energética en un entorno simulado, pero no considera variaciones e incertidumbres propias de un sistema físico en operación. Además, los modelos de predicción de demanda y generación fueron desarrollados mediante regresiones temporales, utilizando un conjunto de datos correspondiente al año 2019 con un muestreo horario. Esto restringe la capacidad del modelo para capturar patrones más complejos y variaciones abruptas en la dinámica de la microrred, especialmente en escenarios con mayor penetración de fuentes renovables intermitentes. Asimismo, una de las principales limitaciones en el control de la microrred es el tiempo de convergencia de los algoritmos basados MPC. A medida que se consideran horizontes de pronóstico más largos (superiores a seis horas) o microrredes con mayor número de nodos, los tiempos de convergencia de los algoritmos de optimización crecen considerablemente, lo que puede dificultar su implementación en aplicaciones de tiempo real, requiriendo unidades de procesamiento con mayor capacidad computacional.

Como trabajo futuro, se propone la implementación de modelos basados en redes neuronales recurrentes, específicamente redes LSTM (*Long Short-Term Memory*), para mejorar la precisión en la predicción de variables energéticas. Sin embargo, esta aproximación requeriría un conjunto de datos más amplio y actualizado, que incluya información detallada sobre la variabilidad de los recursos energéticos y la demanda en distintos contextos operativos. Asimismo, se recomienda explorar estrategias para reducir los tiempos de convergencia de los algoritmos MPC, como el uso de técnicas de descomposición o la implementación de estrategias de control jerárquico. Esto permitiría una validación más robusta de la estrategia de gestión energética y una mejor adaptación a la naturaleza dinámica de las microrredes.

3.6 Conclusiones

En este capítulo se presentan dos enfoques basados en MPC, uno centralizado y uno distribuido, para el despacho óptimo de potencia en microrredes. La gestión centralizada minimiza costos de operación mediante la gestión de la potencia activa y las pérdidas en el sistema mediante la gestión de la potencia reactiva. Para ello se presentan dos modelos, uno

real y otro fasorial, con aproximaciones lineales de las ecuaciones del flujo de carga que facilitan la implementación de los problemas de optimización. También se desarrollan dos algoritmos, uno secuencial y otro unificado, que consiguen puntos óptimos de operación dentro de las condiciones físicas y técnicas de la microrred. Las estrategias propuestas se validan en un esquema de co-simulación e incorporando modelos de predicción de generación renovable y demanda, obteniendo los siguientes resultados principales. Primero, los algoritmos son capaces de encontrar soluciones óptimas en tiempos de convergencia bajos e ideales para aplicaciones en tiempo real. Segundo, los dos modelos propuestos consiguen soluciones similares con una buena aproximación de las ecuaciones del flujo de carga, lo que permite regular la tensión durante el proceso de gestión. Tercero, se garantiza el balance de potencia, consolidando una microrred más confiable y de servicio constante. Cuarto, se logra una reducción significativa en las pérdidas de potencia activa mejorando la eficiencia de todo el sistema. Finalmente, la incorporación de modelos de predicción permite concluir que tanto el algoritmo secuencial como el unificado establecen estrategias de gestión robustas ante perturbaciones como cambios en la generación y la demanda, por lo que la convergencia de los algoritmos casi no se ve afectada por errores de pronóstico en los horizontes de predicción.

Con relación a la gestión distribuida de la potencia activa, se concluye que el algoritmo consigue gestionar costos y programar la carga - descarga de las UAs, con soluciones óptimas próximas a las encontradas por el algoritmo centralizado y en tiempos de convergencia aun útiles para la gestión de microrredes a nivel terciario.

BIBLIOGRAFÍA

[1] L. Meng, M. Savaghebi, F. Andrade, J. C. Vasquez, J. M. Guerrero, and M. Graells, "Microgrid central controller development and hierarchical control implementation in the intelligent microgrid lab of Aalborg University", in *2015 IEEE Applied Power Electronics Conference and Exposition (APEC)*, IEEE, Charlotte, NC, USA, Mar. 2015, pp. 2585–2592. DOI: 10.1109/APEC.2015.7104716.

[2] D. S. Burbano-Benavides, O. D. Ortiz-Sotelo, J. Revelo-Fuelagán, and J. E. Candelo-Becerra, "Design of an on-grid microinverter control technique for managing active and reactive power in a microgrid", *Applied Sciences*, vol. 11, no. 11, p. 4765, May 2021. DOI: 10.3390/app11114765.

[3] D. Rodríguez-Urrego and L. Rodríguez-Urrego, "Photovoltaic energy in Colombia: Current status, inventory, policies and future prospects", *Renewable and Sustainable Energy Reviews*, vol. 92, pp. 160–170, Sep. 2018. DOI: https://doi.org/10.1016/j.rser.2018.04.065.

[4] E. Karatepe, T. Hiyama, *et al.*, "Artificial neural network-polar coordinated fuzzy controller based maximum power point tracking control under partially shaded conditions", *IET Renewable Power Generation*, vol. 3, no. 2, pp. 239–253, Jun. 2009. DOI: 10.1049/iet-rpg:20080065.

[5] N. Karami, N. Moubayed, and R. Outbib, "General review and classification of different mppt techniques", *Renewable and Sustainable Energy Reviews*, vol. 68,

pp. 1–18, Feb. 2017. DOI: https://doi.org/10.1016/j.rser.2016.09.132.

[6] H. F. Ruiz Bravo, J. Revelo Fuelagán, and A. Pantoja, "Control de potencia activa y reactiva de un inversor fotovoltaico trifásico de inyección a red bajo condiciones de sombreado parcial", in *2023 Encuentro Internacional de Educación en Ingeniería (ACOFI EIEI)*, Cartagena, Colombia, Sep. 2023, pp. 1–11. DOI: 10.26507/paper.3267.

[7] M. Miyatake, M. Veerachary, F. Toriumi, N. Fujii, and H. Ko, "Maximum power point tracking of multiple photovoltaic arrays: A PSO approach", *IEEE Transactions on Aerospace and Electronic Systems*, vol. 47, no. 1, pp. 367–380, Jan. 2011. DOI: 10.1109/TAES.2011.5705681.

[8] Y.-H. Liu, S.-C. Huang, J.-W. Huang, and W.-C. Liang, "A particle swarm optimization-based maximum power point tracking algorithm for PV systems operating under partially shaded conditions", *IEEE Transactions on Energy Conversion*, vol. 27, no. 4, pp. 1027–1035, Dec. 2012. DOI: 10.1109/TEC.2012.2219533.

[9] R. B. A. Koad, A. F. Zobaa, and A. El-Shahat, "A novel MPPT algorithm based on Particle Swarm Optimization for photovoltaic systems", *IEEE Transactions on Sustainable Energy*, vol. 8, no. 2, pp. 468–476, Apr. 2017. DOI: 10.1109/TSTE.2016.2606421.

[10] M. Joisher, D. Singh, S. Taheri, D. R. Espinoza-Trejo, E. Pouresmaeil, and H. Taheri, "A hybrid evolutionary-based MPPT for photovoltaic systems under partial shading conditions", *IEEE Access*, vol. 8, pp. 38 481–38 492, Feb. 2020. DOI: 10.1109/ACCESS.2020.2975742.

[11] L. P. Sampaio, M. V. Rocha, S. A. da Silva, and Takami, "Análise comparativa de algoritmos de MPPT bioinspirados nos lobos cinzentos empregando um sistema fotovoltaico conectado à rede elétrica trifásica", *Eletrônica de Potência*, vol. 24, no. 1, pp. 116–127, Mar. 2019. DOI: https://doi.org/10.18618/REP.2019.1.0006.

[12] A. soufyane Benyoucef, A. Chouder, K. Kara, S. Silvestre, and O. A. sahed, "Artificial bee colony based algorithm for maximum power point tracking (MPPT) for PV systems operating under partial shaded conditions", *Applied Soft Computing*, vol. 32, pp. 38–48, Jul. 2015. DOI: https://doi.org/10.1016/j.asoc.2015.03.047.

[13] M. Seyedmahmoudian, B. Horan, R. Rahmani, A. Maung Than Oo, and A. Stojcevski, "Efficient photovoltaic system maximum power point tracking using a new technique", *Energies*, vol. 9, no. 3, p. 147, Mar. 2016. DOI: https://doi.org/10.3390/en9030147.

[14] M. Seyedmahmoudian, T. K. Soon, B. Horan, A. Ghandhari, S. Mekhilef, and A. Stojcevski, "New ARMO-based MPPT technique to minimize tracking time and fluctuation at output of PV systems under rapidly changing shading conditions", *IEEE Transactions on Industrial Informatics*, pp. 1–1, Jan. 2019. DOI: 10.1109/TII.2019.2895066.

[15] C. González-Castaño, C. Restrepo, J. Revelo-Fuelagán, L. L. Lorente-Leyva, and D. H. Peluffo-Ordóñez, "A fast-tracking hybrid MPPT based on surface-based polynomial fitting and p&o methods for solar PV under partial shaded conditions", *Mathematics*, vol. 9, no. 21, p. 2732, Oct. 2021. DOI: https://doi.org/10.3390/math9212732.

[16] A. A. Al-Shammaa, A. M. Abdurraqeeb, A. M. Noman, A. Alkuhayli, and H. M. Farh, "Hardware-in-the-loop validation of direct MPPT based cuckoo search optimization for partially shaded photovoltaic system", *Electronics*, vol. 11, no. 10, p. 1655, May 2022. DOI: https://doi.org/10.3390/electronics11101655.

[17] S. Azmi, G. Adam, S. R. Abdul Rahim, and B. Williams, "Current control of grid connected three phase current source inverter based on medium power renewable energy system", *International Journal of Advanced Technology and Engineering Exploration*, vol. 8, no. 74, pp. 34–44, Jan. 2021. DOI: 10.19101/IJATEE.2020.S2762172.

[18] W. Bai and K. Lee, "Distributed generation system control strategies in microgrid operation", in *19th IFAC World Congress*, vol. 47, Cape Town, South Africa, Aug. 2014, pp. 11 938–11 943. DOI: 10.3182/20140824-6-ZA-1003.02116.

[19] F. Noori and T. Hassan, "Reactive power control of grid-connected photovoltaic micro-inverter based on third-harmonic injection", *International Journal of Power Electronics and Drive Systems (IJPEDS)*, vol. 12, no. 4, pp. 2169–2181, Dec. 2021. DOI: 10.11591/ijpeds.v12.i4.pp2169-2181.

[20] M. L. Kolhe and M. Rasul, "3-phase grid-connected building integrated photovoltaic system with reactive power control capability", *Renewable Energy*, vol. 154, pp. 1065–1075, Jul. 2020. DOI: https://doi.org/10.1016/j.renene.2020.03.075.

[21] Y. Yang and H. Wen, "Adaptive perturb and observe maximum power point tracking with current predictive and decoupled power control for grid-connected photovoltaic inverters", *Journal of Modern Power Systems and Clean Energy*, vol. 7, no. 2, pp. 422–432, Mar. 2019. DOI: 10.1007/s40565-018-0437-x.

[22] S. Golzari, F. Rashidi, and H. F. Farahani, "A Lyapunov function based model predictive control for three phase grid connected photovoltaic converters", *Solar Energy*, vol. 181, pp. 222–233, Mar. 2019. DOI: https://doi.org/10.1016/j.solener.2019.02.005.

[23] H. Khalkhali, A. Oshnoei, and A. Anvari-Moghaddam, "Proportional hysteresis band control for DC voltage stability of three-phase single-stage PV systems", *Electronics*, vol. 11, no. 3, p. 452, Feb. 2022. DOI: https://doi.org/10.3390/electronics11030452.

[24] M. Seyedmahmoudian, R. Rahmani, S. Mekhilef, *et al.*, "Simulation and hardware implementation of new maximum power point tracking technique for partially shaded PV system using hybrid DEPSO method", *IEEE transactions on sustainable energy*, vol. 6, no. 3, pp. 850–862, Apr. 2015. DOI: 10.1109/TSTE.2015.2413359.

[25] K. E. Parsopoulos and M. N. Vrahatis, "Unified particle swarm optimization for solving constrained engineering optimization problems", in *International conference on natural computation*, Springer, vol. 3612, Berlin, Heidelberg, 2005, pp. 582–591. DOI: https://doi.org/10.1007/11539902.

[26] R. Ayop and C. W. Tan, "Design of boost converter based on maximum power point resistance for photovoltaic applications", *Solar Energy*, vol. 160, pp. 322–335, Jan. 2018. DOI: https://doi.org/10.1016/j.solener.2017.12.016.

[27] J. Ahmed and Z. Salam, "A soft computing MPPT for PV system based on cuckoo search algorithm", in *4th International Conference on Power Engineering, Energy and Electrical Drives*, Istanbul, Turkey, Oct. 2013, pp. 558–562. DOI: 10.1109/PowerEng.2013.6635669.

[28] S. Mohanty, B. Subudhi, and P. K. Ray, "A new MPPT design using Grey Wolf optimization technique for photovoltaic system under partial shading conditions", *IEEE Transactions on Sustainable Energy*, vol. 7, no. 1, pp. 181–188, Oct. 2016. DOI: 10.1109/TSTE.2015.2482120.

[29] G. M. Vargas Gil, L. Lima Rodrigues, R. S. Inomoto, A. J. Sguarezi, and R. Machado Monaro, "Weighted-PSO applied to tune sliding mode plus PI controller applied to a boost converter in a PV system", *Energies*, vol. 12, p. 864, Mar. 2019. DOI: https://doi.org/10.3390/en12050864.

[30] M. Tinajero, "Implementación de control óptimo robusto para un inversor trifásico conectado a la red eléctrica", Tesis de Maestría, Facult. Ing. Elec., Univ. Michoacana de San Nicolás de Hidalgo, Morelia, Michoacán, México, 2017. [Online]. Available: http://bibliotecavirtual.dgb.umich.mx:8083/xmlui/handle/DGB_UMICH/3525.

[31] M. Dursun and M. K. DÖŞOĞLU, "LCL filter design for grid connected three-phase inverter", in *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Turkey, Oct. 2018, pp. 1–4. DOI: 10.1109/ISMSIT.2018.8567054..

[32] MathWorks, *Pll (3ph)*, Accessed: Apr. 05, 2022. [Online]. Available: https://www.mathworks.com/help/sps/powersys/ref/pll3ph.html.

[33] K. Ogata, *Sistemas de control en tiempo discreto*, 2nd ed. México: Pearson educación, 1996.

[34] J. M. D. Murillo and E. Mejía, "Estudio comparativo de técnicas PWM de banda de histéresis para el control de corriente en filtros activos de potencia paralelos", *Tecnológicas*, vol. 21, no. 43, pp. 91–106, Oct. 2018. DOI: https://doi.org/10.22430/22565337.1058.

[35] MathWorks, *Pwm generator*, Accessed: Apr. 10, 2022. [Online]. Available: https://la.mathworks.com/help/sps/powersys/ref/pwmgenerator2level.html.

[36] K. Prakash, P. Vejju, and B. V. Reddy, "Multiport switch based mppt for stand-alone photovoltaic power systems", in *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*, Delhi, India, Jul. 2016, pp. 1–6. DOI: 10.1109/ICPEICES.2016.7853251.

[37] OPAL-RT, *Rt-lab documentation*, Accessed: Apr. 10, 2022. [Online]. Available: https://opal-rt.atlassian.net/wiki/spaces/PRD/overview.

[38] D. S. Burbano-Benavides, O. D. Ortiz-Sotelo, J. Revelo-Fuelagán, and J. E. Candelo-Becerra, "Design of an on-grid microinverter control technique for managing active and reactive power in a microgrid", *Applied Sciences*, vol. 11, no. 11, May 2021. DOI: 10.3390/app11114765.

[39] A. Bidram and A. Davoudi, "Hierarchical structure of microgrids control system", *IEEE Transactions on Smart Grid*, vol. 3, no. 4, pp. 1963–1976, May 2012. DOI: 10.1109/TSG.2012.2197425.

[40] M. H. Cintuglu, T. Youssef, and O. A. Mohammed, "Development and application of a real-time testbed for multiagent system interoperability: A case study on hierarchical microgrid control", *IEEE Transactions on Smart Grid*, vol. 9, no. 3, pp. 1759–1768, Aug. 2018. DOI: 10.1109/TSG.2016.2599265.

[41] J. M. Guerrero, J. C. Vasquez, J. Matas, L. G. de Vicuna, and M. Castilla, "Hierarchical control of droop-controlled AC and DC microgrids—a general approach toward standardization", *IEEE Transactions on Industrial Electronics*, vol. 58, no. 1, pp. 158–172, Aug. 2011. DOI: 10.1109/TIE.2010.2066534.

[42] L. Rodríguez, A. Pantoja, and J. Revelo Fuelagán, "Análisis de controladores secundarios sintonizados mediante un algoritmo modificado de enjambre de partículas en una microrred aislada", in *2023 Encuentro Internacional de Educación en Ingeniería (ACOFI EIEI)*, Cartagena, Colombia, Sep. 2023, pp. 1–12. DOI: https://doi.org/10.26507/paper.3242.

[43] J. M. Ramírez and E. Gómez, *Control en microrredes de AC: Control jerárquico, tecnologías y normativa*, Accessed: Jan. 25, 2022. [Online]. Available: http://www.cigrecolombia.org/Documents/Documentos.

[44] M. A. Ebrahim, B. A. Aziz, F. A. Osman, and M. N. F. Nashed, "Optimal PI based secondary control for autonomous micro-grid via particle swarm optimization technique", in *2018 Twentieth International Middle East Power Systems Conference (MEPCON)*, Cairo, Egypt, Dec. 2018, pp. 1148–1155. DOI: 10.1109/MEPCON.2018.8635217.

[45] A. Bidram and A. Davoudi, "Hierarchical structure of microgrids control system", *IEEE Transactions on Smart Grid*, vol. 3, no. 4, pp. 1963–1976, Dec. 2012. DOI: 10.1109/TSG.2012.2197425.

[46] F. Guo, C. Wen, J. Mao, and Y.-D. Song, "Distributed secondary voltage and frequency restoration control of droop-controlled inverter-based microgrids", *IEEE Transactions on Industrial Electronics*, vol. 62, no. 7, pp. 4355–4364, Jul. 2015. DOI: 10.1109/TIE.2014.2379211.

[47] A. Bidram, A. Davoudi, F. L. Lewis, and J. M. Guerrero, "Distributed cooperative secondary control of microgrids using feedback linearization", *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 3462–3470, Aug. 2013. DOI: 10.1109/TPWRS.2013.2247071.

[48] A. Bidram, A. Davoudi, F. L. Lewis, and Z. Qu, "Secondary control of microgrids based on distributed cooperative control of multi-agent systems", *IET Generation, Transmission & Distribution*, vol. 7, no. 8, pp. 822–831, Aug. 2013. DOI: https://doi.org/10.1049/iet-gtd.2012.0576.

[49] Q. Shafiee, J. M. Guerrero, and J. C. Vasquez, "Distributed secondary control for islanded microgrids—a novel approach", *IEEE Transactions on Power Electronics*, vol. 29, no. 2, pp. 1018–1031, Feb. 2014. DOI: 10.1109/TPEL.2013.2259506.

[50] Q. Li, C. Peng, M. Wang, M. Chen, J. M. Guerrero, and D. Abbott, "Distributed secondary control and management of islanded microgrids via dynamic weights", *IEEE Transactions on Smart Grid*, vol. 10, no. 2, pp. 2196–2207, Mar. 2019. DOI: 10.1109/TSG.2018.2791398.

[51] D. O. Amoateng, M. Al Hosani, M. S. Elmoursi, K. Turitsyn, and J. L. Kirtley, "Adaptive voltage and frequency control of islanded multi-microgrids", *IEEE Transactions on Power Systems*, vol. 33, no. 4, pp. 4454–4465, Jul. 2018. DOI: 10.1109/TPWRS.2017.2780986.

[52] X. Wu, C. Shen, and R. Iravani, "A distributed, cooperative frequency and voltage control for microgrids", *IEEE Transactions on Smart Grid*, vol. 9, no. 4, pp. 2764–2776, Jul. 2018. DOI: 10.1109/TSG.2016.2619486.

[53] N. M. Dehkordi, N. Sadati, and M. Hamzeh, "Distributed robust finite-time secondary voltage and frequency control of islanded microgrids", *IEEE Transactions on Power Systems*, vol. 32, no. 5, pp. 3648–3659, Sep. 2017. DOI: 10.1109/TPWRS.2016.2634085.

[54] Z. Jin, L. Meng, J. M. Guerrero, and R. Han, "Hierarchical control design for a shipboard power system with DC distribution and energy storage aboard future more-electric ships", *IEEE Transactions on Industrial Informatics*, vol. 14, no. 2, pp. 703–714, Feb. 2018. DOI: 10.1109/TII.2017.2772343.

[55] S. Abhinav, I. D. Schizas, and A. Davoudi, "Noise-resilient synchrony of AC microgrids", in *2015 Resilience Week (RWS)*, Philadelphia, PA, USA, Aug. 2015, pp. 1–6. DOI: 10.1109/RWEEK.2015.7287418.

[56] N. M. Dehkordi, H. R. Baghaee, N. Sadati, and J. M. Guerrero, "Distributed noise-resilient secondary voltage and frequency control for islanded microgrids", *IEEE Transactions on Smart Grid*, vol. 10, no. 4, pp. 3780–3790, Jul. 2019. DOI: 10.1109/TSG.2018.2834951.

[57] S. Liu, X. Wang, and P. X. Liu, "Impact of communication delays on secondary frequency control in an islanded microgrid", *IEEE Transactions on Industrial Electronics*, vol. 62, no. 4, pp. 2021–2031, Apr. 2015. DOI: 10.1109/TIE.2014.2367456.

[58] E. A. Coelho, D. Wu, J. M. Guerrero, *et al.*, "Small-signal analysis of the microgrid secondary control considering a communication time delay", *IEEE Transactions on Industrial Electronics*, vol. 63, no. 10, pp. 6257–6269, Oct. 2016. DOI: 10.1109/TIE.2016.2581155.

[59] M. E. Romero and M. M. Seron, "Ultimate boundedness of voltage droop control with distributed secondary control loops", *IEEE Transactions on Smart Grid*, vol. 10, no. 4, pp. 4107–4115, Jul. 2019. DOI: 10.1109/TSG.2018.2849583.

[60] Y. Xu, Q. Guo, H. Sun, and Z. Fei, "Distributed discrete robust secondary cooperative control for islanded microgrids", *IEEE Transactions on Smart Grid*, vol. 10, no. 4, pp. 3620–3629, Jul. 2019. DOI: 10.1109/TSG.2018.2833100.

[61] S. K. Sahoo, A. K. Sinha, and N. K. Kishore, "Control techniques in AC, DC, and hybrid AC–DC microgrid: A review", *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 6, no. 2, pp. 738–759, Jun. 2018. DOI: 10.1109/JESTPE.2017.2786588.

[62] S. Ahmadi, S. Shokoohi, and H. Bevrani, "A fuzzy logic-based droop control for simultaneous voltage and frequency regulation in an AC microgrid", *International Journal of Electrical Power Energy Systems*, vol. 64, pp. 148–155, Jan. 2015. DOI: https://doi.org/10.1016/j.ijepes.2014.07.024.

[63] H. Karimi, M. T. Beheshti, A. Ramezani, and H. Zareipour, "Intelligent control of islanded AC microgrids based on adaptive neuro-fuzzy inference system", *International Journal of Electrical Power Energy Systems*, vol. 133, p. 107 161, Dec. 2021. DOI: https://doi.org/10.1016/j.ijepes.2021.107161.

[64] N. Eghtedarpour and E. Farjah, "Power control and management in a hybrid AC/DC microgrid", *IEEE Transactions on Smart Grid*, vol. 5, no. 3, pp. 1494–1505, May 2014. DOI: 10.1109/TSG.2013.2294275.

[65] X. Shen, H. Wang, J. Li, Q. Su, and L. Gao, "Distributed secondary voltage control of islanded microgrids based on RBF-neural-network sliding-mode technique", *IEEE Access*, vol. 7, pp. 65 616–65 623, May 2019. DOI: 10.1109/ACCESS.2019.2915509.

[66] M. Dursun and M. K. Dosoglu, "LCL filter design for grid connected three-phase inverter", in *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Turkey, Oct. 2018, pp. 1–4. DOI: 10.1109/ISMSIT.2018.8567054.

[67] M. Rasheduzzaman, J. A. Mueller, and J. W. Kimball, "An accurate small-signal model of inverter- dominated islanded microgrids using dq reference frame", *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 2, no. 4, pp. 1070–1080, Dec. 2014. DOI: 10.1109/JESTPE.2014.2338131.

[68] W. Yao, M. Chen, J. Matas, J. M. Guerrero, and Z.-M. Qian, "Design and analysis of the droop control method for parallel inverters considering the impact of the complex impedance on the power sharing", *IEEE Transactions on Industrial Electronics*, vol. 58, no. 2, pp. 576–588, Feb. 2011. DOI: 10.1109/TIE.2010.2046001.

[69] G. Julio, O. Leony, A. Alexander, P. Wilson, and R. Milton, "An hybrid algorithm based NARX for non-linear identification and modeling of an AC/DC hybrid microgrid simulation", in *2022 IEEE Sixth Ecuador Technical Chapters Meeting (ETCM)*, Quito, Ecuador, Oct. 2022, pp. 1–6. DOI: 10.1109/ETCM56276.2022.9935724.

[70] M. Shi, X. Chen, J. Zhou, Y. Chen, J. Wen, and H. He, "PI-consensus based distributed control of AC microgrids", *IEEE Transactions on Power Systems*, vol. 35, no. 3, pp. 2268–2278, May 2020. DOI: 10.1109/TPWRS.2019.2950629.

[71] Q. Shafiee, J. M. Guerrero, and J. C. Vasquez, "Distributed secondary control for islanded microgrids—a novel approach", *IEEE Transactions on Power Electronics*, vol. 29, no. 2, pp. 1018–1031, Feb. 2014. DOI: 10.1109/TPEL.2013.2259506.

[72] Q. Shafiee, V. Nasirian, J. C. Vasquez, J. M. Guerrero, and A. Davoudi, "A multi-functional fully distributed control framework for AC microgrids", *IEEE Transactions on Smart Grid*, vol. 9, no. 4, pp. 3247–3258, Jul. 2018. DOI: 10.1109/TSG.2016.2628785.

[73] M. Nrgaard, O. E. Ravn, N. K. Poulsen, and L. K. Hansen, *Neural Networks for Modelling and Control of Dynamic Systems: A Practitioner's Handbook*, 1st ed. Berlin, Heidelberg: Springer-Verlag, 2000, ISBN: 1852332271.

[74] J. D. Bomberger and D. E. Seborg, "Determination of model order for NARX models directly from input-output data", *Journal of Process Control*, vol. 8, no. 5, pp. 459–468, Dec. 1998. DOI: https://doi.org/10.1016/S0959-1524(98)00013-4.

[75] K. P. Schneider, B. Mather, B. Pal, *et al.*, "Analytic considerations and design basis for the IEEE distribution test feeders", *IEEE Transactions on power systems*, vol. 33, no. 3, pp. 3181–3188, May 2018. DOI: 10.1109/TPWRS.2017.2760011.

[76] P. S. Georgilakis and N. D. Hatziargyriou, "Optimal distributed generation placement in power distribution networks: Models, methods, and future research", *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 3420–3428, Aug. 2013. DOI: 10.1109/TPWRS.2012.2237043.

[77] J. G. Ordóñez, J. Revelo, A. Pantoja, and J. Barco-Jímenez, "Gestión predictiva de microrredes para el despacho de potencias activa y reactiva con una aproximación convexa", in *Encuentro Internacional de Educación en Ingeniería (ACOFI)*, Cartagena, Colombia, Sep. 2023, pp. 1–12. DOI: https://doi.org/10.26507/paper.3297.

[78] D. Razmi and T. Lu, "A literature review of the control challenges of distributed energy resources based on microgrids (MGs): Past, present and future", *Energies*, vol. 15, no. 13, p. 4676, Jun. 2022. DOI: https://doi.org/10.3390/en15134676.

[79] C. Bordons, F. Garcia-Torres, and M. A. Ridao, "Model predictive control of microgrids", in 1st ed. Spain: Springer Cham, Sep. 2020, vol. 358, ch. 2, pp. 25–44. DOI: https://doi.org/10.1007/978-3-030-24570-2.

[80] B. P. Koirala, E. Koliou, J. Friege, R. A. Hakvoort, and P. M. Herder, "Energetic communities for community energy: A review of key issues and trends shaping integrated community energy systems", *Renewable and Sustainable Energy Reviews*, vol. 56, pp. 722–744, Apr. 2016. DOI: https://doi.org/10.1016/j.rser.2015.11.080.

[81] A. Muhtadi, D. Pandit, N. Nguyen, and J. Mitra, "Distributed energy resources based microgrid: Review of architecture, control, and reliability", *IEEE Transactions on Industry Applications*, vol. 57, no. 3, pp. 2223–2235, May 2021. DOI: 10.1109/TIA.2021.3065329.

[82] A. Garcés Ruiz, *Optimización convexa: aplicaciones en operación y dinámica de sistemas de potencia*, 1st ed. Pereira, Colombia: Universidad Tecnológica de Pereira, 2020, p. 307. DOI: https://doi.org/10.22517/9789587224658.

[83] K. B. Sahay, A. Sonkar, and A. Kumar, "Economic load dispatch using genetic algorithm optimization technique", in *2018 International Conference and Utility Exhibition on Green Energy for Sustainable Development (ICUE)*, IEEE, Phuket, Thailand, Oct. 2018, pp. 1–5. DOI: 10.23919/ICUE-GESD.2018.8635729.

[84] T. Yalcinoz and K. Rudion, "Economic load dispatch using an improved particle swarm optimization based on functional constriction factor and functional inertia weight", in *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe*

(EEEIC/I&CPS Europe), IEEE, Genova, Italy, Jun. 2019, pp. 1–5. DOI: 10.1109/EEEIC.2019.8783432.

[85] M. Yousif, Q. Ai, Y. Gao, W. A. Wattoo, Z. Jiang, and R. Hao, "An optimal dispatch strategy for distributed microgrids using PSO", *CSEE Journal of Power and Energy Systems*, vol. 6, no. 3, pp. 724–734, Sep. 2019. DOI: 10.17775/CSEEJPES.2018.01070.

[86] D.-A. Ramirez, A. Garces, and J.-J. Mora-Florez, "A convex approximation for the tertiary control of unbalanced microgrids", *Electric Power Systems Research*, vol. 199, p. 107 423, Oct. 2021. DOI: https://doi.org/10.1016/j.epsr.2021.107423.

[87] W. Gil-González, O. D. Montoya, L. F. Grisales-Noreña, F. Cruz-Peragón, and G. Alcalá, "Economic dispatch of renewable generators and BESS in DC microgrids using second-order cone optimization", *Energies*, vol. 13, no. 7, p. 1703, Apr. 2020. DOI: https://doi.org/10.3390/en13071703.

[88] Y. Du, W. Pei, N. Chen, X. Ge, and H. Xiao, "Real-time microgrid economic dispatch based on model predictive control strategy", *Journal of modern power systems and clean energy*, vol. 5, no. 5, pp. 787–796, Sep. 2017. DOI: 10.1007/s40565-017-0265-4.

[89] L. Ye, C. Zhang, Y. Tang, *et al.*, "Hierarchical model predictive control strategy based on dynamic active power dispatch for wind power cluster integration", *IEEE Transactions on Power Systems*, vol. 34, no. 6, pp. 4617–4629, Nov. 2019. DOI: 10.1109/TPWRS.2019.2914277.

[90] D. Erazo-Caicedo, E. Mojica-Nava, and J. Revelo-Fuelagán, "Model predictive control for optimal power flow in grid-connected unbalanced microgrids", *Electric Power Systems Research*, vol. 209, p. 108 000, Aug. 2022. DOI: https://doi.org/10.1016/j.epsr.2022.108000.

[91] K. Chreng, H. S. Lee, and S. Tuy, "A hybrid model for electricity demand forecast using improved ensemble empirical mode decomposition and recurrent neural networks with ERA5 climate variables", *Energies*, vol. 15, no. 19, p. 7434, Oct. 2022. DOI: https://doi.org/10.3390/en15197434.

[92] M. Mukhtar, A. Oluwasanmi, N. Yimen, *et al.*, "Development and comparison of two novel hybrid neural network models for hourly solar radiation prediction", *Applied Sciences*, vol. 12, no. 3, p. 1435, Jan. 2022. DOI: https://doi.org/10.3390/app12031435.

[93] J. Barco-Jiménez, F. Eraso-Checa, A. Pantoja, and E. Caicedo-Bravo, "Estimation of global solar radiation using NNARX neural networks based on the UV index", *Tecnura*, vol. 25, no. 70, pp. 41–50, Aug. 2021. DOI: https://doi.org/10.14483/22487638.18638.

[94] A. Alkesaiberi, F. Harrou, and Y. Sun, "Efficient wind power prediction using machine learning methods: A comparative study", *Energies*, vol. 15, no. 7, p. 2327, Mar. 2022. DOI: https://doi.org/10.3390/en15072327.

[95] B. Nepal, M. Yamaha, A. Yokoe, and T. Yamaji, "Electricity load forecasting using clustering and ARIMA model for energy management in buildings", *Japan Architectural Review*, vol. 3, no. 1, pp. 62–76, Dec. 2020. DOI: https://doi.org/10.1002/2475-8876.12135.

[96] B. Belmahdi, M. Louzazni, and A. El Bouardi, "One month-ahead forecasting of mean daily global solar radiation using time series models", *Optik*, vol. 219, p. 165 207, Oct. 2020. DOI: https://doi.org/10.1016/j.ijleo.2020.165207.

[97] S. Feng, D. Yang, B. Zhou, Y. Luo, and G. Li, "Real-time active power dispatch of virtual power plant based on distributed model predictive control", *Electronics Letters*, vol. 58, no. 23, pp. 872–875, Oct. 2022. DOI: https://doi.org/10.1049/ell2.12640.

[98] D. Zhou, X. Niu, Y. Xie, P. Li, J. Fang, and F. Guo, "An economic dispatch method of microgrid based on fully distributed admm considering demand response", *Sustainability*, vol. 14, no. 7, p. 3751, Mar. 2022. DOI: https://doi.org/10.3390/su14073751.

[99] G. Chen and Q. Yang, "An ADMM-based distributed algorithm for economic dispatch in islanded microgrids", *IEEE Transactions on Industrial Informatics*, vol. 14, no. 9, pp. 3892–3903, Sep. 2018. DOI: 10.1109/TII.2017.2785366.

[100] S. K. Akula and H. Salehfar, "Energy management system for interconnected microgrids using alternating direction method of multipliers (ADMM)", in *2018 North American Power Symposium (NAPS)*, IEEE, Fargo, ND, USA, Sep. 2018, pp. 1–6. DOI: 10.1109/NAPS.2018.8600647.

[101] N. España, J. Barco-Jiménez, A. Pantoja, and N. Quijano, "Distributed population dynamics for active and reactive power dispatch in islanded microgrids", *International Journal of Electrical Power & Energy Systems*, vol. 125, p. 106 407, Feb. 2021. DOI: https://doi.org/10.1016/j.ijepes.2020.106407.

[102] M. A. Velasquez, J. Barreiro-Gomez, N. Quijano, A. I. Cadena, and M. Shahidehpour, "Distributed model predictive control for economic dispatch of power systems with high penetration of renewable energy resources", *International Journal of Electrical Power & Energy Systems*, vol. 113, pp. 607–617, Dec. 2019. DOI: https://doi.org/10.1016/j.ijepes.2019.05.044.

[103] J. Zhu, *Optimization of power system operation*, 2nd ed. Hoboken, New Jersey, USA and Canada: John Wiley & Sons, 2015, p. 629.

[104] F. Garcia-Torres and C. Bordons, "Optimal economical schedule of hydrogen-based microgrids with hybrid storage using model predictive control", *IEEE Transactions on Industrial Electronics*, vol. 62, no. 8, pp. 5195–5207, Aug. 2015. DOI: 10.1109/TIE.2015.2412524.

[105] M. Alramlawi, E. Mohagheghi, and P. Li, "Predictive active-reactive optimal power dispatch in PV-battery-diesel microgrid considering reactive power and battery lifetime costs", *Solar Energy*, vol. 193, pp. 529–544, Nov. 2019. DOI: https://doi.org/10.1016/j.solener.2019.09.034.

[106] S. Duman, Y. Sönmez, U. Güvenç, and N. Yörükeren, "Optimal reactive power dispatch using a gravitational search algorithm", *IET generation, transmission & distribution*, vol. 6, no. 6, pp. 563–576, Jun. 2012. DOI: 10.1049/iet-gtd.2011.0681.

[107] A. Garces, *Mathematical Programming for Power Systems Operation: From Theory to Applications in Python*, 1st ed. Hoboken, New Jersey, USA and Canada: John Wiley & Sons, 2021.

[108] J. Barco-Jiménez, G. Obando, H. R. Chamorro, A. Pantoja, E. C. Bravo, and J. A. Aguado, "In-line distributed dispatch of active and reactive power based on admm and consensus considering battery degradation in microgrids", *IEEE Access*, vol. 11, pp. 31 479–31 495, Feb. 2023. DOI: 10.1109/ACCESS.2023.3248958.

[109] V. Gevorgian, R. Wallen, P. Koralewicz, E. Mendiola, S. Shah, and M. Morjaria, "Provision of grid services by PV plants with integrated battery energy storage system", National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., Nov. 2020.

[110] S. Daneshvardehnavi, C. A. Negri, K. E. K. Schmitt, S. Bayne, and M. Giesselmann, "A case study for connecting bidirectional PEV station for reactive power support to the gleamm prototype microgrid", in *2021 IEEE Green Technologies Conference (GreenTech)*, IEEE, Denver, CO, USA, Apr. 2021, pp. 19–25. DOI: 10.1109/GreenTech48523.2021.00014.

[111] C. Tautiva, A. Cadena, and F. Rodriguez, "Optimal placement of distributed generation on distribution networks", in *2009 44th International Universities Power Engineering Conference (UPEC)*, IEEE, Glasgow, UK, Sep. 2009, pp. 1–5.

[112] Power-Sonic, *The complete guide to lithium vs lead acid batteries*, Accessed: Sep. 25, 2022. [Online]. Available: https://www.power-sonic.com/blog/lithium-vs-lead-acid-batteries/.

[113] Enair, *Datasheet serie einare70pro*, Accessed: Sep. 25, 2022. [Online]. Available: https://www.enair.es/es/aerogeneradores/e70pro.

[114] S. Pfenninger and I. Staffell, "Long-term patterns of european PV output using 30 years of validated hourly reanalysis and satellite data", *Energy*, vol. 114, pp. 1251–1265, Nov. 2016. DOI: https://doi.org/10.1016/j.energy.2016.08.060.

[115] C. G. Castellanos Domínguez and Y. S. Shinakov, “Análisis de aleatoriedad en señales y sistemas”, in 1st ed. Manizales, Colombia: Universidad Nacional de Colombia-Sede Manizales, 2007, ch. 3, pp. 115–172.

[116] D. Zhou, X. Niu, Y. Xie, P. Li, J. Fang, and F. Guo, “An economic dispatch method of microgrid based on fully distributed ADMM considering demand response”, *Sustainability*, vol. 14, no. 7, p. 3751, Mar. 2022. DOI: https://doi.org/10.3390/su14073751.

[117] Y. Men, J. Zhang, X. Lu, and T. Hong, “Artificial intelligence (ai) based black-box modeling algorithm for system identification in three-phase single-stage pv inverter systems”, in *2023 IEEE Energy Conversion Congress and Exposition (ECCE)*, IEEE, Nashville, TN, USA, Dec. 2023, pp. 27–32. DOI: 10.1109/ECCE53617.2023.10362832.

LISTA DE FIGURAS

1.1 Diagrama del convertidor DC/DC 17

1.2 Modelo equivalente de k módulos PV, modificado de [24] 19

1.3 Diagrama del inversor 32

1.4 Modelo promediado inversor trifásico 34

1.5 Estructura interna de un PLL 36

1.6 Esquema de control del inversor con el regulador PI resonante 39

1.7 Esquema de control mediante banda de histéresis 41

1.8 Estructura Maestro- Consola del archivo en simulink en el entorno RT-LAB 42

1.9 Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 1 44

1.10 Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 2 45

1.11 Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 3 47

1.12 Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos para el perfil de irradiancia del caso 4 48

1.13 Gráfica de potencia vs tiempo del sistema fotovoltaico para cada uno de los métodos híbridos donde se varía las PSC 49

1.14 Comparación de las técnicas híbridas MPPT según los 5 primeros aspectos 50

1.15 Gráfica de potencias activas vs tiempo del inversor trifásico para cada uno de los controladores empleados en Simulink y en RT-LAB 52

Potencias activas Simulink 52

Potencias activas RT-LAB 52

1.16 Gráfica de potencias reactivas vs tiempo del inversor trifásico para cada uno de los controladores empleados en simulink y en RT-LAB 53

Potencias reactivas Simulink 53

Potencias reactivas RT-LAB 53

1.17 Gráficas de potencias activas y reactivas vs el tiempo del inversor trifásico para cada uno de los controladores empleados en el segundo escenario de prueba en Simulink y en RT-LAB 56

Potencias activas Simulink 56

Potencias activas RT-LAB 56

Potencias reactivas Simulink 56

Potencias reactivas RT-LAB 56

1.18 Potencias activas y reactivas del inversor, la carga y la red eléctrica para el controlador PI 57

Potencias activas Simulink 57

Potencias activas RT-LAB 57

Potencias reactivas Simulink 57

Potencias reactivas RT-LAB 57

1.19 Potencias activas y reactivas del inversor, la carga y la red eléctrica para el controlador PI resonante 58

Potencias activas Simulink 58

Potencias activas RT-LAB 58

Potencias reactivas Simulink 58

Potencias reactivas RT-LAB 58

1.20 Potencias activas y reactivas del inversor, la carga y la red eléctrica para el controlador por banda de Histéresis 59

Potencias activas Simulink 59

Potencias activas RT-LAB 59

Potencias reactivas Simulink 59

Potencias reactivas RT-LAB 59

2.1 Esquema general de una GD 65

2.2 Estructura interna de un PLL, modificado de [32] 67

2.3 Estructura de las líneas de transmisión entre nodos 68

2.4 Curvas características de frecuencia ω y voltaje v en relación con la potencia activa y reactiva (P,Q) 70

2.5 Esquema del control primario 71

2.6 Resistencia virtual en el bus de un GD 72

2.7 Estructura general control secundario de Ebrahim. Adaptado de [44] 73

2.8 Diagrama general de un controlador MRAC 74

2.9 Esquema control neuronal tipo MRAC off-line 75

2.10 Estructura general control de voltaje de Mengxuan. Adaptado de [70] 77

2.11 Estructura general control de frecuencia de Mengxuan. Adapatado de [70] 78

2.12 Estructura general control secundario de frecuencia de Shaffie 2014. Adaptado de [71] 79

2.13 Estructura general control secundario de voltaje Shaffie 2014. Adaptado de [71] 80

2.14 Estructura general control secundario de voltaje de Shaffie 2016. Adaptado de [72] 81

2.15 Estructura general control secundario de frecuencia de Shaffie 2016. Adaptado de [72] 82

2.16 Señales de entrada generada: (a) uω MG, (b) uω planta de referencia, (c) uv MG, (d) uv planta de referencia 85

2.17 Curvas de respuesta obtenidas: (a) vPCC original, (b) vPCC preprocesada, (c) ωPCC original, (d) ωPCC preprocesada 86

2.18 Diagrama algoritmo DEPSO, modificado de [24] 89

2.19 Diagrama de la red de prueba elegida 90

2.20 Estructura Maestro- Consola del archivo en Simulink en el entorno OPAL-RT 92

2.21 Curvas de respuesta de la red de prueba en magnitud de voltaje en Simulink: (a) GD1, (b) GD2, (c) GD3, (d) Promedio de todos los nodos. 94

2.22 Curvas de respuesta de la red de prueba en potencia reactiva en Simulink: (a) Controlador Ebrahim, (b) Controlador Megxuan, (c) Controlador Shaffie 2014,(d) Controlador Shaffie 2016 95

2.23 Curvas de respuesta de la red de prueba en magnitud de frecuencia en Simulink: (a) GD1, (b) GD2, (c) GD3, (d) Promedio de todos los nodos 97

2.24 Curvas de respuesta de la red de prueba en magnitud de voltaje en la máquina de simulación en tiempo real: (a) GD1, (b) GD2, (c) GD3, (d) Promedio de todos los nodos 99

2.25 Curvas de respuesta de la red de prueba en potencia reactiva en la máquina de simulación en tiempo real: (a) Controlador Ebrahim, (b) Controlador Megxuan, (c) Controlador Shaffie 2014, (d) Controlador Shaffie 2016 100

2.26 Curvas de respuesta de la red de prueba en magnitud de frecuencia en la máquina de simulación en tiempo real: (a) GD1, (b) GD2, (c) GD3, (d) Promedio de todos los nodos 101

3.1 Requerimientos de los controladores MPC y topología de una microrred de gestión centralizada 108

3.2 Esquema de la microrred basada en la red IEEE de 13 nodos. 117

3.3 Demanda total agregada en diez días consecutivos. 118

3.4 Ejemplo de recursos energéticos solar y eólico disponible en la Universidad de Nariño durante diez días consecutivos. 119

3.5 Comparación de perfiles de demanda: medidos - pronosticados 122

3.6 Comparación de perfiles de irradiancia: medidos - pronosticados 122

3.7 Comparación de perfiles de velocidad del viento: medidos - pronosticados 123

3.8 Diagrama de co-simulación 123

3.9 Comparación del balance de potencia activa y reactiva: Control no predictivo - MPC 124

3.10 Comparación de perfiles de despacho de potencia activa: Control no predictivo - MPC 124

3.11 Comparación del estado de carga de las unidades de almacenamiento: Control no predictivo - MPC 125

3.12 Comparación de costos por generación: Control no predictivo - MPC 126

3.13 Comparación de perfiles de despacho de potencia reactiva: Control no predictivo - MPC 126

3.14 Comparación de voltajes de nodo: Control no predictivo - MPC 127

3.15 Comparación de pérdidas en potencia activa: Control no predictivo - MPC 127

3.16 Comparación de perfiles de despacho de potencia activa del generador diésel: MPC con horizonte de predicción ideal - MPC con estimación de demanda y generación a partir del promedio de datos anteriores - MPC incorporando modelos de predicción 128

3.17 Comparación de perfiles de despacho de las unidades de almacenamiento: Horizonte de predicción ideal - Estimación promedio - Modelos ARIMA 129

3.18 Comparación del estado de carga de las unidades de almacenamiento: Horizonte de predicción ideal - Estimación promedio - Modelos ARIMA 129

3.19 Comparación de los perfiles de despacho de potencia reactiva de los generadores diésel y fotovoltaico obtenidos al evaluar el algoritmo MPC con: estimación ideal, estimación a partir del promedio de datos anteriores y estimación con modelos de predicción 130

3.20 Comparación de los perfiles de despacho de potencia reactiva de las unidades de almacenamiento al emplear MPC con: estimación ideal, estimación a partir del promedio de datos anteriores y estimación con modelos de predicción..... 131

3.21 Comparación de costos por generación y pérdidas de potencia activa en 3 escenarios de control: MPC con horizonte de predicción ideal, MPC con estimación de demanda y generación a partir del promedio de datos anteriores y MPC incorporando modelos de predicción 131

3.22 Comparación de la desviación de los voltajes de nodo: MPC con ecuaciones de flujo no lineales - MPC con ecuaciones de flujo linealizadas 132

3.23 Comparación de los perfiles de despacho de potencia reactiva de los generadores diésel, fotovoltaico y eólico, al aplicar MPC con ecuaciones de flujo no lineales y con ecuaciones de flujo linealizadas 133

3.24 Comparación de los perfiles de despacho de potencia reactiva de las unidades de almacenamiento, al aplicar MPC con ecuaciones de flujo no lineales y con ecuaciones de flujo linealizadas 133

3.25 Comparación de las p´erdidas en potencia activa: MPC con ecuaciones de flujo no lineales - MPC con ecuaciones de flujo linealizadas 134

3.26 Comparación de los perfiles de generación de potencia activa del generador diésel (G1) y las UAs (BT1 y BT2): algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial 135

3.27 Comparación de los estados de carga de las UAs: algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial 136

3.28 Comparación de los perfiles de generación en potencia reactiva de los generadores diésel (G1), fotovoltaico (G2) y eólico(G3): algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial 136

3.29 Comparación de los perfiles de generación de potencia reactiva de las UAs: algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial 137

3.30 Comparación de las pérdidas y los costos por generación: algoritmo secuencial - algoritmo unificado modelo real - algoritmo unificado modelo fasorial 137

3.31 Gestión distribuida de microrredes conformadas por sistemas energéticos independientes 140

3.32 Enlaces de comunicación para la gestión distribuida 143

3.33 Proceso iterativo del algoritmo distribuido en el controlador del generador diésel para diferentes valores del parámetro de sintonización u 143

3.34 Perfiles de despacho en potencia activa de los generadores diésel (G1), fotovoltaico (G2) y eólico (G3) obtenidos con los algoritmos centralizado y distribuido 144

3.35 Perfiles de despacho en potencia activa de las UAs obtenidos con los algoritmos centralizado y distribuido 145

3.36 Comparación de los estados de carga de las unidades de almacenamiento obtenidos con el algoritmo distribuido con los encontrados con el algoritmo centralizado 145

LISTA DE TABLAS

1.1 Parámetros de la celda fotovoltaica 18

1.2 Parámetros del inversor trifásico 33

1.3 Escenario de prueba en PSC variables 49

1.4 Similitud y Factor de seguimiento del punto GMPP 51

1.5 Métricas potencia activa 54

1.6 Métricas potencia reactiva 54

1.7 Métricas potencia activa RT-LAB 56

1.8 Métricas potencia reactiva RT-LAB 57

2.1 Características de los controladores 90

2.2 Parámetros de las GDs 91

2.3 Métricas de correlación RT-LAB-Simulink 93

2.4 Métricas de comparación de controladores centralizados en Simulink 98

2.5 Métricas de comparación de controladores distribuidos en Simulink 98

2.6 Métricas de comparación centralizados Opal 102

2.7 Métricas de comparación distribuidos Opal 103

3.1 Coeficientes de costo para cada tipo de generador 117

3.2 Límites de capacidad y factor de potencia para cada GD y UA en la microrred. 118

3.3 Modelos de predicción 121

3.4 Costo acumulado y pérdidas totales en diez días de gestión 138

3.5 Tiempo promedio de convergencia de los algoritmos centralizados 139

3.6 Tiempo promedio de convergencia 146

SOBRE LOS AUTORES

Juan Gabriel Ordoñez

Ingeniero electrónico y magister en ingeniería electrónica de la Universidad de Nariño (Colombia). Estudiante de doctorado en Ingeniería en la Universidad Nacional de Colombia Sede Manizales. Asistente de investigación (2021-2022) del proyecto BPIN 2020000100041 (financiado por el SGR, Colombia). Pasante de maestría en la Universidad Tecnológica de Pereira - UTP (Colombia) (2022). Sus líneas de trabajo son microrredes, gestión y eficiencia energética.

Harold Fernando Ruíz Bravo

Ingeniero electrónico y aspirante a magister en Ingeniería Electrónica de la Universidad de Nariño (Colombia). Realizó una pasantía de maestría en las universidades del Valle y de Nariño (Colombia), en el marco del proyecto BPIN 2020000100041 (financiado por el SGR, Colombia). Asistente de investigación con la Universidad de Antioquia (Colombia) en el marco del Proyecto P14 de la Alianza por la Sostenibilidad Energética para Colombia - SÉNECA. Experiencia en sistemas de generación distribuida con sistemas fotovoltaicos bajo condiciones de sombreado parcial y simulación de microrredes eléctricas en plataformas de simulación en tiempo real.

Laura María Rodríguez Rivera

Ingeniera electrónica y aspirante a magister en Ingeniería Electrónica de la Universidad de Nariño (Colombia). Asistente de investigación (2021-2022) del proyecto BPIN 2020000100041 (financiado por el SGR, Colombia). Pasante de maestría en la Universidad del Valle (Colombia) (2022). Experiencia en control de microrredes, generación distribuida con sistemas fotovoltaicos y simulación de microrredes eléctricas en plataformas de simulación en tiempo real.

Javier Revelo Fuelagán

Ingeniero Electrónico, Magister en Ingeniería – Automatización Industrial y Doctor en Ingeniería – Automática egresado de la Universidad Nacional de Colombia Sede Manizales. Es profesor tiempo completo de la Universidad de Nariño (Colombia), adscrito al Departamento de Electrónica desde 2012 y miembro del Grupo de Investigación en Ingeniería Eléctrica y Electrónica – GIIEE. Sus líneas de trabajo son el análisis de calidad de la potencia, control de convertidores electrónicos, generación distribuida y control en microrredes.

Andrés Darío Pantoja Bucheli

Ingeniero electrónico de la Universidad Nacional de Colombia Sede Manizales, magister en ingeniería electrónica y de computadores y doctor en ingeniería de la Universidad de los Andes (Colombia). Realizó una pasantía posdoctoral en la Universidad Estatal de Ohio (USA) financiado por la beca Fulbright Investigador Visitante Colombiano. Es profesor tiempo completo de la Universidad de Nariño (Colombia), adscrito al Departamento de Electrónica desde 2003 y miembro del Grupo de Investigación en Ingeniería Eléctrica y Electrónica – GIIEE. Sus líneas de trabajo son el control en microrredes, optimización distribuida y procesamiento de señales fisiológicas para control.

êditorial
Universidad de **Nariño**

Año de publicación: 2025
San Juan de Pasto - Nariño - Colombia

Este libro presenta un análisis detallado del control jerárquico en microrredes, desde el control primario hasta el control terciario. Se contempla el modelado matemático, el diseño de algoritmos de control y el análisis de los resultados de simulaciones de diversos escenarios de operación de microrredes. En el control primario, se diseñan controles para un inversor capaz de inyectar potencia activa y reactiva a la red eléctrica, con el propósito de mejorar la eficiencia de los sistemas de generación fotovoltaica, especialmente bajo condiciones de sombreado parcial. Desde el enfoque de control secundario, se analiza el desempeño de estrategias de control centralizadas y distribuidas en microrredes, enfocadas en la regulación de los niveles de tensión y de frecuencia para aumentar la estabilidad y confiabilidad frente a la integración de fuentes de energía renovable. Finalmente, en el ámbito del control terciario, se presentan modelos de control orientados al despacho óptimo de potencia activa, considerando la incertidumbre presente tanto en la generación como en la demanda de energía.

ISBN: 978-628-7771-37-6

9 786287 771376

Universidad de Nariño
FUNDADA EN 1904

Universidad de Nariño
ACREDITADA EN ALTA CALIDAD
RESOLUCIÓN MEN 000022 - ENERO 11 DE 2023

120 Años
Universidad de Nariño

êditorial
Universidad de Nariño

campus verde