



UNIVERSIDAD TECNOLÓGICA NACIONAL

Facultad Regional Santa Fe

Doctorado en Ingeniería – mención Industrial

Tesis Doctoral

Estrategias para la Gestión de Energía en Microrredes Eléctricas con Integración de Energías Renovables

Ing. Rodrigo Manuel Schierloh

Director: Dr. Jorge Ruben Vega

Co-Directores: Dr. Fabio Miguel Vincitorio

Dr. José Luis Godoy

Santa Fe, Argentina

Agosto 2024

Schierloh, Rodrigo Manuel

Estrategias para la gestión de energía en microrredes eléctricas con integración de energías renovables / Rodrigo Manuel Schierloh ; Ilustrado por Rodrigo Manuel Schierloh. - 1a ed - Paraná : Rodrigo Manuel Schierloh, 2024.

Libro digital, PDF/A

Archivo Digital: descarga y online

ISBN 978-631-00-4855-0

1. Tesis Doctorales. 2. Energía Eléctrica. 3. Energía Renovable. I. Título.

CDD 621.3071

UNIVERSIDAD TECNOLÓGICA NACIONAL
Facultad Regional Santa Fe

Se presenta esta Tesis en cumplimiento de los requisitos exigidos por la Universidad Tecnológica Nacional para la obtención del grado académico de Doctor en Ingeniería mención Industrial.

**Estrategias para la Gestión de Energía en
Microrredes Eléctricas con Integración de Energías
Renovables**

Ing. Rodrigo Manuel Schierloh

Director: Dr. Jorge Ruben Vega

Co-Directores: Dr. Fabio Miguel Vincitorio
Dr. José Luis Godoy

Jurados: Dr. Patricio Donato
Dr. Diego Feroldi
Dr. David Zumoffen

Santa Fe, Argentina

Julio 2024

Agradecimientos

A mi familia, por el apoyo incondicional, por los valores inculcados y por incentivar me siempre a estudiar y a aprender. A mis referentes: papá y mamá. A mi hermana, mi hermano, mi sobrina y a Aye. A mis cuatro abuelos, siempre presentes en mi memoria.

A la Universidad Tecnológica Nacional, por otorgarme una beca doctoral y financiar este trabajo.

A la Facultad Regional Paraná, por el apoyo y la confianza.

A mi director, Jorge, por ser mi faro, por guiarme en este camino.

A mi co-director, Fabio, por sus consejos y su calidez como persona.

A mi otro co-director, José Luis, por inculcarme la pasión por la investigación, por su ayuda y su motivación.

A Fulbright y al Consejo Federal de Inversiones, por financiar mi estadía de investigación en Estados Unidos.

A la *Florida International University*, por aceptarme como investigador durante tres meses.

A mi director en la FIU, Osama Mohammed, por abrirme las puertas del *Energy Systems Research Laboratory* y por compartir desinteresadamente su sabiduría.

A mis amigos, por su contención. A Leo y a Piri.

A mis compañeros de estudio y de trabajo. A Sergio, Rafin, Abhishek y Ahmed.

Publicaciones de la Tesis

Durante el desarrollo de esta Tesis, se publicaron un total de 6 trabajos científicos, 3 de los cuales son artículos publicados en revistas internacionales y los restantes 3 son artículos presentados en congresos internacionales. Los mismos se listan a continuación, según constituyen los capítulos de la Tesis:

Capítulo 2:

- Publicaciones en revistas internacionales:

- [I] R. M. Schierloh, S. N. Bragagnolo, J. R. Vega, y J. C. Vaschetti, “Real-Time predictive management of a multi-unit HVAC system based on heuristic optimization. A health center case study”, *Energy and Buildings*, vol. 295, p. 113315, sep. 2023, doi: 10.1016/j.enbuild.2023.113315.
- [II] S. N. Bragagnolo, R. M. Schierloh, J. R. Vega, y J. C. Vaschetti, “Demand response strategy applied to planning the operation of an air conditioning system. Application to a medical center”, *Journal of Building Engineering*, vol. 57, p. 104927, oct. 2022, doi: 10.1016/j.jobbe.2022.104927.

Capítulo 3:

- Publicación en revista internacional:

- [III] J. L. Godoy y R. M. Schierloh, “Predictive management of the hybrid generation dispatch and the dispatchable demand response in microgrids with heating, ventilation, and air-conditioning (HVAC) systems”, *Sustainable Energy, Grids and Networks*, vol. 32, p. 100857, dic. 2022, doi: 10.1016/j.segan.2022.100857

- Presentación en congreso internacional:

- [IV] R. M. Schierloh, J. R. Vega, F. M. Vincitorio, y J. L. Godoy, “Control Predictivo Conjunto del Despacho de Generación Híbrida y de la Demanda Incluyendo Climatización en Microrredes”, en 2020 Argentine Conference, *IEEE ARGENCON*, 2020.

Capítulo 4:

- Presentaciones en congresos internacionales:

- [V] R. M. Schierloh, J. L. Godoy, F. M. Vincitorio y L. C. Salcedo, "A Fault Supervision Method for Inslanded and Converters-Based Microgrids with Integration of Renewable Generation", en CLAGTEE 2022, Río de Janeiro, nov. 2022. ISBN: 9788564689022.
- [VI] R. M. Schierloh, J. L. Godoy, F. M. Vincitorio, y J. R. Vega, “Simulación y Análisis de Fallas Eléctricas en una Microrred Aislada con Integración de Generación Fotovoltaica y Almacenamiento en Baterías”, en 2021 *IEEE URUCON*, nov. 2021, pp. 138–142. doi: 10.1109/URUCON53396.2021.9647183.

- Publicaciones en revista internacional:

[VII] R. M. Schierloh, A. Ahmadi, J. L. Godoy y O. Mohammed, “Fault Protection Method for Converters-Based DC Microgrids with Integration of Renewable Energy”. Manuscrito en redacción para ser enviado a IEEE Transactions on Power Systems.

Capítulo 5

- Presentaciones en congreso internacional

[VIII] J. L. Godoy, R. M. Schierloh, y J. Vega, “Economic Evaluation of Micro-Grids with Renewable Generation”, en 2018 Argentine Conference on Automatic Control (AADECA), nov. 2018, pp. 1–6. doi: 10.23919/AADECA.2018.8577305.

Las publicaciones de trabajos en colaboración durante el doctorado son las siguientes:

[IX] J. D. Cortez, S. N. Bragagnolo, R. M. Schierloh y J. Amaya, “Estudio Térmico de la Vivienda Pampeana Sur I y Gestión de su Demanda Eléctrica, Incluyendo el Control de Los Aires Acondicionados”, en XX Reunión de Trabajo en Procesamiento de la Información y Control (RPIC), nov. 2023, pp. 79–84. ISBN 978-950-766-230-0.

[X] S. N. Bragagnolo, R. M. Schierloh, J. C. Vaschetti, y J. R. Vega, “Optimización del Costo Eléctrico de Grandes Demandas en Argentina por Medio de la Gestión Predictiva del Sistema de Climatización”, en 2022 IEEE Biennial Congress of Argentina (ARGENCON), sep. 2022, pp. 1–8. doi: 10.1109/ARGENCON55245.2022.9939919.

[XI] S. N. Bragagnolo, R. M. Schierloh, J. R. Vega, y J. C. Vaschetti, “Gestión de la Demanda Aplicada al Sistema de Climatización de un Centro Médico”, en 27o Congreso Argentino de Control Automático AADECA’20 Virtual, CABA, Argentina, nov. 2020, pp. 277–288.

[XII] R. M. Schierloh, F. M. Vincitorio, y J. L. Godoy, “Iluminación pública sustentable por autogeneración renovable para municipios grandes usuarios de energía”, en Libro de Resúmenes LUZ 2019 de las XIV Jornadas Argentinas de Luminotecnia, 2019, pp. 33–35.

Índice general

Abreviaturas	XIV
Resumen.....	XV
1 Introducción.....	1
1.1 Antecedentes y motivación.....	1
1.1.1 Control en microrredes.....	2
1.1.2 Gestión de sistemas de climatización.....	4
1.1.3 Desafíos de los sistemas de protección en microrredes	4
1.2 Organización y estructura de la Tesis.....	6
2 Gestión Predictiva en Tiempo Real de Sistemas de Climatización Basada en Optimización Heurística	9
2.1 Resumen del capítulo.....	9
2.2 Introducción.....	9
2.2.1 Antecedentes	11
2.2.2 Motivación	14
2.2.3 Contribución.....	15
2.3 Metodología.....	16
2.3.1 Gestión de la demanda	16
2.3.2 Modelo térmico	17
2.3.3 Confort térmico	19
2.3.4 Control Predictivo basado en Modelo (MPC).....	21
2.3.5 Modelo de predicción de variables.....	24
2.4 Aplicación.....	26
2.4.1 Esquema tarifario aplicado al Centro de Salud	28
2.4.2 Formulación del controlador predictivo del Centro de Salud	29
2.5 Simulaciones.....	33
2.5.1 Simulaciones y parámetros del algoritmo genético.....	34
2.5.2 Resultados	34
2.6 Discusión	40
3 Gestión predictiva del despacho de generación y de la demanda aplicable a microrredes que incluyen sistemas de climatización	41
3.1 Resumen del capítulo.....	41
3.2 Introducción.....	42

3.3	Problemas de estudio	46
3.3.1	Microrred 1.....	47
3.3.2	Microrred 2.....	48
3.4	Soluciones propuestas.....	50
3.4.1	Predicciones	51
3.4.2	Formulación del MPC para la microrred 1 (aislada).....	52
3.4.3	Formulación del MPC de la microrred 2 (con conexión a la red).....	57
3.4.4	Resumen del esquema MPC desarrollado.....	60
3.5	Aplicación y resultados de las simulaciones	60
3.5.1	Caso 1 de estudio: granja avícola automatizada.....	60
3.5.2	Caso 2 de estudio: centro de salud	65
3.6	Discusión	69
4	Sistema de protección para microrredes DC.....	70
4.1	Resumen del capítulo.....	70
4.2	Introducción.....	71
4.3	Método propuesto	73
4.3.1	Asunciones	74
4.3.2	Modelado de fallas en líneas	74
4.3.3	Aplicación de los modelos básicos de fallas a una microrred.....	76
4.3.4	Algoritmo de protección.....	80
4.4	Entorno de simulación para la evaluación del método	83
4.4.1	Caso de Estudio	83
4.4.2	Modelo de la microrred	84
4.4.3	Simulaciones y resultados	88
4.5	Discusión	93
5	Diseño, instalación y puesta en marcha de generación fotovoltaica en granja avícola de Entre Ríos.....	95
5.1	Resumen del capítulo.....	95
5.2	Introducción.....	95
5.3	HOMER Pro®	97
5.4	Estudio del caso y propuesta	99
5.4.1	Normativa y reglamentación	99
5.4.2	Información de la granja	100
5.4.3	Evaluación tecno-económica.....	101

5.5	Instalación y puesta en marcha.....	106
5.5.1	Circuito eléctrico.....	106
5.5.2	Configuración del inversor.....	107
5.5.3	Estructura.....	108
5.5.4	Fotos de la micro-generación.....	108
5.5.5	Resultados de la instalación.....	110
5.6	Discusión.....	112
6	Conclusiones y trabajos futuros.....	114
6.1	Conclusiones.....	114
6.2	Trabajos futuros.....	115

Índice de figuras

Figura 1.1. Jerarquía de control en microrredes [8].	2
Figura 1.2. Principales problemáticas de los sistemas de protección de fallas en MRs.	5
Figura 1.3. Estructura de la Tesis.	8
Figura 2.1. Principales estrategias de gestión de la demanda [57].	17
Figura 2.2. Arriba: diagrama de salas contiguas. Abajo: modelo RC equivalente (refrigeración de la sala 1).	18
Figura 2.3. Escala del <i>PMV</i> .	19
Figura 2.4. Diagrama esquemático de un MPC [66].	22
Figura 2.5. Plano del centro de salud.	26
Figura 2.6. Diagrama de cajas de la demanda de potencia de cada mes.	27
Figura 2.7. Demanda de potencia promedio de cada mes.	27
Figura 2.8. Perfiles promedio de temperatura exterior (arriba), demanda base (medio) y potencia térmica emitida por humanos en la sala 5 (abajo).	31
Figura 2.9. Diagrama de cajas del <i>PMV</i> para la estrategia MPC usando modelos de predicción y la estrategia de bandas de temperatura para a) salas de baja prioridad, b) salas de alta prioridad.	37
Figura 2.10. Perfiles de temperatura interiores diarias para a) MPC con $N = 4$ y b) control por banda de temperatura con RP.	38
Figura 2.11. Evolución diaria del <i>PMV</i> de las salas de baja prioridad para a) MPC con $N = 4$ y b) control por banda de temperatura con RP.	38
Figura 2.12. Evolución diaria del <i>PMV</i> para las salas de alta prioridad para a) MPC con $N = 4$ y b) control por banda de temperatura con RP.	39
Figura 2.13. Demanda de potencia diaria utilizando la estrategia MPC con $N = 4$ y el control por banda de temperatura con RP.	39
Figura 3.1. Topología de la microrred 1.	47
Figura 3.2. Modelo eléctrico RC equivalente para un sistema de climatización (funcionando como calefacción).	48
Figura 3.3. Topología de la microrred 2.	49
Figura 3.4. Subdivisión del centro de salud en tres grandes zonas.	50
Figura 3.5. Evolución temporal de las variables controladas T_i y SoC respecto a sus setpoints ($T_{i,s}$ y SoC_s), comparados con la temperatura externa T_e y la generación fotovoltaica P_{PV} , respectivamente.	63

Figura 3.6. Flujo de potencia en el bus del sistema (generación y demanda). Evolución temporal de las variables manipuladas (P_{PV} , P_G , P_D), de la potencia del banco de baterías (P_B) y de la demanda de la carga no despachable (P_{ND}).....	63
Figura 3.7. Desempeño a lazo cerrado del controlador propuesto. Evolución temporal de las variables controladas (T_1 , T_2 , T_3 , SoC), de las variables manipuladas (P_1 , P_2 , P_3 , P_B), y una de las perturbaciones medidas (T_e).....	67
Figura 3.8. Desempeño a lazo cerrado del controlador propuesto. Evolución temporal de las variables involucradas en el balance generación-consumo (L_T , P_{MG} , P_B , P_{PV} , P_{ND}) en relación con la demanda de potencia pico (T_h) permitida por la tarifa contratada.	68
Figura 4.1. Modelo para fallas de cortocircuito.	75
Figura 4.2. Modelo para fallas de circuito abierto.	76
Figura 4.3. Topología y diagrama unifilar de la microrred de estudio para el desarrollo del método de protección de fallas.	77
Figura 4.4. Algoritmo para la detección, identificación, localización y aislación de falla.	80
Figura 4.5. Topología de la microrred simulada.	83
Figura 4.6. Esquema del convertidor DC-DC de los paneles fotovoltaicos.....	85
Figura 4.7. Esquema del convertidor (elevador-reductor) de las baterías.....	86
Figura 4.8. Esquema del inversor.....	87
Figura 4.9. Controladores de corriente y tensión del inversor.	88
Figura 4.10. Generación de las señales de los transistores del inversor.	88
Figura 4.11. Detección/identificación del método para escenarios 3.....	90
Figura 4.12. Señales de corriente y tensión del escenario 3.....	90
Figura 4.13. Detección/identificación del método para escenarios 7 – 9.....	91
Figura 4.14. Detección/identificación del método para escenarios 10 – 12.....	92
Figura 4.15. Señales de corriente y tensión del escenario 11.....	92
Figura 4.16. Detección/identificación del método para el escenario 13.....	93
Figura 4.17. Señales de corriente y tensión del escenario 13.....	93
Figura 5.1. Diagrama del funcionamiento de HOMER Pro.....	97
Figura 5.2. Ubicación de la granja.	100
Figura 5.3. Ubicación de los galpones.	100
Figura 5.4. Valores promedios diarios mensuales de GHI e índice de nubosidad en Valle María.	102
Figura 5.5. Perfiles diarios promedios de cada mes (gráfico obtenido con HOMER Pro®).....	102

Figura 5.6. Generación promedio mensual.	106
Figura 5.7. Diagrama unifilar de la micro-generación.	107
Figura 5.8. Disposición de los cuatro <i>strings</i> de paneles.	108
Figura 5.9. Gabinete del inversor y de los tableros de protección.	109
Figura 5.10. Tablero de protección de CC (izquierda) y AC (derecha).	109
Figura 5.11. Estructura de soporte de los paneles y gabinete del inversor.	109
Figura 5.12. Potencia promedio de la demanda consumo de la granja y de la generación fotovoltaica.	111

Índice de tablas

Tabla 2.1. Comparación del esquema propuesto con trabajos similares.....	13
Tabla 2.2. Tarifas aplicadas al centro de salud (enero de 2023 para usuarios de baja tensión [69]).....	28
Tabla 2.3. Parámetros térmicos de las salas del centro de salud.....	30
Tabla 2.4. Comparación de las estrategias.....	35
Tabla 2.5. Desempeño de la estrategia optimizada para diferentes horizontes con predicción perfecta.....	36
Tabla 3.1. Desempeño a lazo cerrado de cuatro escenarios de control simulados para el mes de enero.....	64
Tabla 4.1. Escenarios de falla simulados.....	89
Tabla 5.1. Consumo de energía bimestral de la granja.....	101
Tabla 5.2. Cuadro tarifario de ENERSA para demandas medianas (T2), vigente desde el 1° de junio al 31 de julio de 2022.....	103
Tabla 5.3. Resultados de la simulación de HOMER Pro®.....	105
Tabla 5.4. Dispositivos de protección en cada tablero.....	107
Tabla 5.5. Datos del funcionamiento de la micro-generación (período de 1/02/2023-01/11/2023).....	110
Tabla 5.6. Factura de energía para conexión T2, T2 con micro-generación y T2 con micro-generación y gestión de energía.....	112

ABREVIATURAS

AC	<i>Alternating current</i> , corriente alterna
AG	Algoritmo genético
BMS	<i>Battery management system</i>
CB	<i>Circuit breaker</i>
CoP	<i>Coefficient of performance</i> , coeficiente de rendimiento
CPU	<i>Central Processing Unit</i> , unidad central de procesamiento.
CS	Centro de salud
DC	<i>Direct current</i> , corriente continua
DR	<i>Demand Response</i> , respuesta a la demanda
DSM	<i>Demand Side Management</i> , gestión de la demanda
GD	Generación Distribuida
GR	Generación Renovable
HVAC	<i>Heating, ventilation and air conditioning</i> . Sistemas de climatización.
IHG	<i>Internal heat gain</i>
LCOE	<i>Levelized cost of energy</i> , costo nivelado de energía
LP	<i>Liner programming</i> , programación lineal
LPV	<i>Linear parameter varying</i>
MPC	<i>Model Predictive Control</i> , control predictivo basado en modelo
MPPT	<i>Maximum Power Point Tracker</i>
MR	Microrred
NPC	<i>Net Present Cost</i> , costo actual neto
OC	<i>Open circuit</i> , circuito abierto
PMV	<i>Predicted Mean Vote</i> , voto medio estimado
PV	Photovoltaics, fotovoltaico
QP	<i>Quadratic programming</i> , programación cuadrática
RC	Resistivo - capacitivo
RP	Recorte de pico
REI	Redes Eléctricas Inteligentes
SC	<i>Short circuit</i> , corto circuito
SoC	<i>State of charge</i> , estado de la carga de baterías
SPWM	<i>Sinusoidal Pulse Width Modulation</i>
SSCB	<i>Solid state circuit breaker</i> , interruptor de estado sólido
TOU	<i>Time of use</i> , tarifa horaria

RESUMEN

Las Redes Eléctricas Inteligentes surgieron como solución al crecimiento energético mundial, a raíz de la necesidad de migrar a un esquema sostenible y sustentable. Dentro de este nuevo paradigma, la Generación Distribuida y la Generación Renovable son partes fundamentales que dan origen a las microrredes eléctricas. Las microrredes con integración de generación renovable presentan una serie de desafíos tecnológicos en cuanto a la gestión de energía y a los sistemas de protección. Estos desafíos surgen a partir de los diferentes modos de operación de las microrredes, la variedad de topologías posibles, la variabilidad de los recursos renovables y la utilización de convertidores electrónicos.

Las estrategias de gestión de energía mejoran el desempeño y la estabilidad de las microrredes. Pueden aplicarse tanto en el lado de la carga -a través de esquemas de gestión de la demanda-, o en el lado de la generación -a través de estrategias de despacho de potencia-, o en ambos lados simultáneamente. Por otra parte, los sistemas de protección deben considerar que los flujos de potencia en las microrredes son bidireccionales y que los convertidores electrónicos tienen una contribución de potencia limitada durante las fallas. En consecuencia, las protecciones tradicionales basadas en corriente no son efectivas.

Esta tesis pretende investigar los principales desafíos antes mencionados y desarrollar soluciones integrales, para luego aplicarlas en casos de interés regional. Se desarrollan diversos esquemas de gestión de energía en microrredes con y sin conexión a red, aplicados tanto a los recursos de energía distribuidos como a las cargas controlables. En particular, como cargas controlables se considera el caso de los sistemas de climatización. Estos sistemas tienen una elevada demanda de potencia y un gran consumo de energía, por lo que el desarrollo de estrategias de gestión de la demanda puede disminuir el consumo energético sin perder el confort térmico.

Primero, se propone un esquema de gestión de la demanda aplicado a sistemas de climatización multi-unidad y multi-zona que maximiza el confort térmico mientras minimiza el gasto de la factura eléctrica. La gestión en tiempo real de los equipos de climatización se basa en un control predictivo que incorpora un modelo térmico análogo a un circuito resistivo-capacitivo. El problema de optimización del controlador se resuelve con un enfoque heurístico, particularmente utilizando un algoritmo genético y evaluando el confort térmico a través del voto medio estimado (*Predicted Mean Vote*, PMV), que es un índice de sensación térmica. En la formulación también se incluyen modelos simples de predicción de variables como

temperatura exterior, ocupación de salas y demanda de las cargas, desarrollados a través de reconciliación de niveles con perfiles promedios. El esquema se aplica al sistema de climatización de un centro de salud ubicado en Entre Ríos y se compara con un control por banda de temperatura. Las simulaciones muestran que la gestión desarrollada mejora significativamente el confort térmico (hasta un 47%) además de disminuir el costo en la factura eléctrica (disminución del 23%).

Además, se desarrolla un esquema de control predictivo basado en modelo para la gestión conjunta del despacho de generación y de la demanda en microrredes que incluyen sistemas de climatización. De esta manera, tanto los dispositivos de almacenamiento y generación como los equipos de climatización se gestionan simultáneamente, mejorando el aprovechamiento energético de la microrred sin perder el confort térmico. Este esquema utiliza modelos simples de baterías y del sistema de climatización, además de contemplar modelos sencillos de predicción de variables como temperatura, radiación solar y demanda de la carga. La gestión propuesta se aplica a dos casos de estudio de interés en Argentina: i) una granja avícola aislada de la red que incorpora paneles fotovoltaicos, baterías y generador diésel, y ii) el centro de salud previamente mencionado, pero incorporando generación fotovoltaica y baterías. Las simulaciones realizadas evidencian que, para el caso aislado, la estrategia proporciona un ahorro de combustible del 55% con un mejor aprovechamiento de los recursos en comparación con un controlador convencional basado en reglas. Para el caso conectado a red, proporciona un ahorro mensual en la factura del 26%.

Por otro lado, se desarrolla un esquema de protección para líneas de microrredes DC capaz de mejorar su resiliencia a partir de detectar, identificar, localizar y aislar fallas de cortocircuito y circuito abierto. Se trata de un método de aplicación práctica basado en la comunicación y en modelos sencillos de falla, que proporciona una capa de protección adicional a las tradicionales de corriente. El método requiere conocer las tensiones y las corrientes en las cargas y en los convertidores electrónicos, utilizando la capacidad de comunicación que estos últimos poseen actualmente para enviar información a una central de cómputo. La central resuelve un problema de optimización que incorpora modelos de las líneas de la microrred, y determina si se produjo una falla, de qué tipo es y dónde sucedió. A partir de la ubicación de la falla, la central envía una señal armónica de apertura a los *circuits breakers* asociados al tramo fallado, utilizando las líneas de la microrred como canal de comunicación. El método se aplica al lado DC de la microrred aislada mencionada anteriormente. Las simulaciones llevadas a cabo muestran que

el método funciona correctamente en todos los escenarios de fallas planteados, incluso frente a cortocircuitos con alta impedancia, baja radiación solar y baja carga en baterías.

Por último, se describen las etapas de planificación, instalación y puesta en marcha de 24 kW_p de generación fotovoltaica en una granja avícola conectada a red, ubicada en la localidad de Valle María, Entre Ríos. El caso abordado es de interés regional teniendo en cuenta que la industria avícola de la provincia es líder a nivel nacional. El dimensionamiento de la generación se realizó con el software HOMER Pro®, considerando la reglamentación vigente y la información de consumo brindada por el usuario. A partir del resultado favorable de la evaluación económica efectuada con el mismo software, se prosiguió con la instalación completa de la generación. Finalmente se puso en marcha y conectó a la red de la distribuidora provincial el 1° de febrero de 2023, siendo una de las primeras conexiones a la distribuidora para este nivel de potencia. Al 1° de febrero de 2024, la instalación generó 35658 kWh de los cuales 9843 kWh fueron consumidos por las cargas y el excedente fue inyectado a red. Durante este período, la instalación fotovoltaica brindó una reducción del 31% (reducción de USD 3738) del costo de energía en relación al caso hipotético de la misma granja sin generación. Sin embargo, se evalúa un segundo caso hipotético, que incorpora 24 kW_p de generación fotovoltaica y además una gestión ideal de la energía. En este caso, la reducción fue del 64% (reducción de USD 7676). Esto demuestra que una correcta gestión de energía para maximizar el autoconsumo puede aumentar los beneficios, disminuir el capital necesario y lograr una amortización más rápida.

Capítulo 1:

INTRODUCCIÓN

1.1 Antecedentes y motivación

En los últimos tiempos el interés socio-político por alcanzar la sostenibilidad y sustentabilidad energética ha crecido notablemente. En consecuencia, nuevos esquemas en el ámbito científico han comenzado a desarrollarse. En este contexto, surge el paradigma de las Redes Eléctricas Inteligentes (REI) que representa la transición del sistema de energía tradicional, basado en combustibles fósiles y generación concentrada, hacia un nuevo esquema amigable con el medio ambiente que incorpora Generación Distribuida (GD), Generación Renovable (GR) y sistemas de almacenamiento de energía. Este cambio paradigmático acarrea consigo nuevos desafíos en cuanto a la gestión energética y a los sistemas de protección [1].

Una microrred (MR) eléctrica es un grupo de cargas interconectadas y de recursos de energía distribuidos, dentro de límites eléctricos definidos, que actúa como una entidad controlable con respecto a una red de distribución de energía eléctrica. Este sistema de potencia eléctrica está intencionalmente planeado para incluir recursos distribuidos (generadores de energía eléctrica y/o calor, sistemas de almacenamiento, etc.), que en forma temporaria pueden estar (o no) vinculados al resto del sistema interconectado [2]. Las MRs se conciben especialmente para tener una alta penetración de energía renovable (eólica, fotovoltaica, hidrocinética, biomasa, etc.) y se las ubica cerca de los centros de consumo para suministrar buena calidad de energía eléctrica con bajas pérdidas de transmisión [3]. Las MRs pueden contribuir a mejorar el funcionamiento global de una red de distribución, reduciendo las pérdidas técnicas y los tiempos de interrupción, mejorando la confiabilidad y optimizando la integración de recursos energéticos distribuidos.

Una MR debe suministrar de manera segura la energía eléctrica demandada por las cargas, utilizando generadores y dispositivos de almacenamiento de manera eficiente, tanto en condiciones normales de operación como en situaciones de contingencia, e independientemente que posea o no conexión a la red de distribución [4]. El desarrollo de las MRs se enfrenta a retos operacionales asociados a la utilización de generación renovable y la consecuente incertidumbre producida por la intermitencia de los recursos, además de la baja inercia que poseen los convertidores electrónicos para suministrar picos de potencia [5]. Por otro lado, la utilización de distintos recursos de energía distribuidos produce flujos de potencia

bidireccionales dentro de una microrred, hecho que puede provocar malfuncionamiento en los sistemas de protección además de producir problemas de estabilidad [6].

1.1.1 Control en microrredes

En general, la literatura considera tres niveles jerárquicos de control para la operación de microrredes, que poseen distintas escalas de tiempo (Figura 1.1) [7]. El nivel primario funciona en una escala de tiempo pequeña (del orden de los milisegundos) y se encarga principalmente de la estabilidad de la tensión y frecuencia durante los cambios en la generación, en la carga o tras los cambios de modo de funcionamiento (de conexión a red a modo isla y viceversa). Este nivel de control, es implementado dentro de los convertidores electrónicos de los generadores y de los dispositivos de almacenamiento.

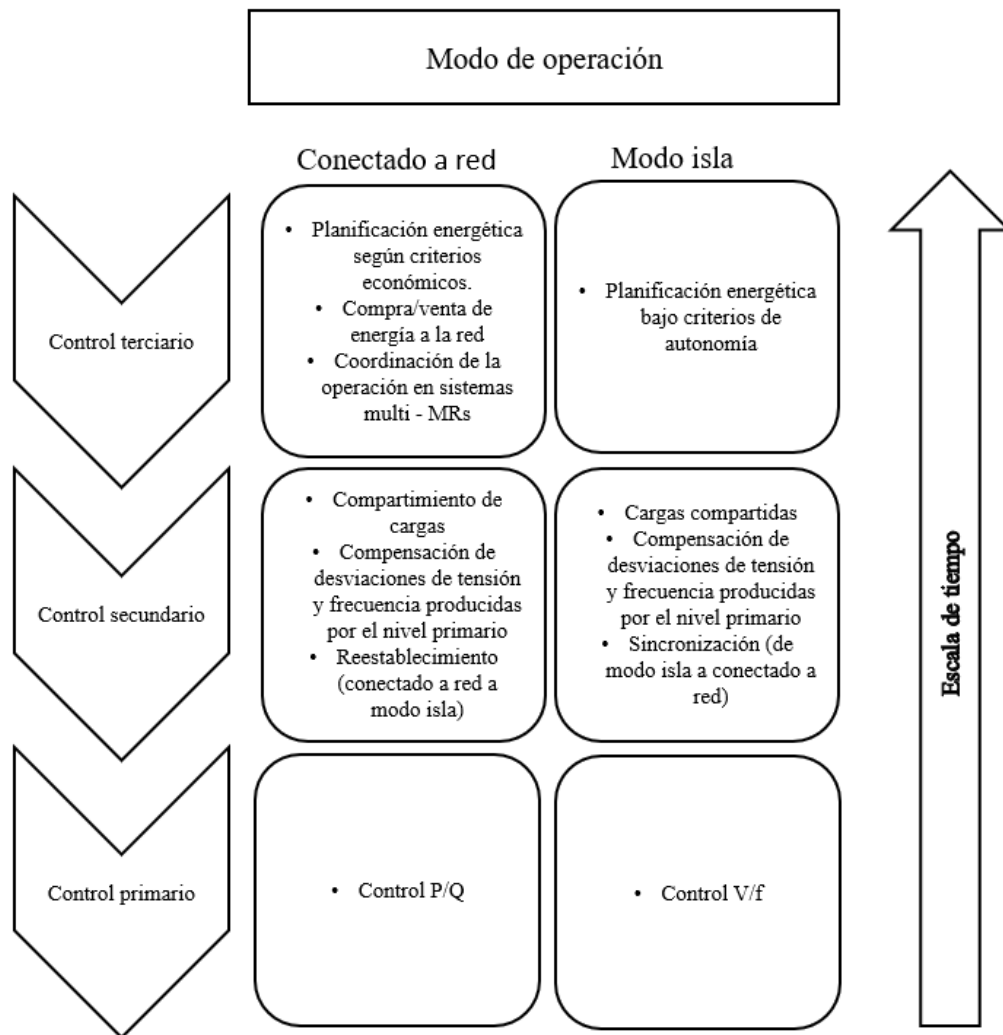


Figura 1.1. Jerarquía de control en microrredes [8].

El control secundario se encarga de eliminar las desviaciones de tensión y frecuencia ante un cambio de carga o generación en la MR. También elimina cualquier error en estado estacionario producido por el control primario, además de realizar la sincronización con la red previo cambio del modo isla a conexión a red.

Por último, el control terciario gestiona los flujos de potencia entre la MR, la red de distribución o entre MRs, utilizando escalas de tiempo más grandes (minutos, horas o días).

La gestión de energía hace referencia a un control comprendido entre el nivel 2 y 3 de la jerarquía, y las estrategias implementadas dependen del tamaño de la microrred [9]. El principal objetivo de la gestión de energía en microrredes pequeñas es la operación segura, es decir, el balance entre generación y demanda. En este caso, es muy común la utilización de algoritmos heurísticos y metaheurísticos, así como la utilización de métodos de control de banda de histéresis. Estos últimos son ampliamente utilizados en el control del estado de carga de baterías (*state of charge*, SoC); su implementación es muy sencilla, pero no permiten incluir criterios económicos ni se obtienen resultados óptimos [10]. Por otro lado, trabajos recientes proponen estrategias de gestión de energía basadas en algoritmos de aprendizaje maquina, más precisamente utilizando aprendizaje por refuerzo, como *Q-Learning* [11], [12].

El control predictivo basado en modelo (*Model Predictive Control*, MPC) posee ventajas sobre otros esquemas de control aplicados a gestión de microrredes dado que permite considerar distintos criterios de control e incluir restricciones físicas y operativas [4]. Adicionalmente, es posible incluir modelos de predicción de generación y demanda en la formulación del problema de optimización, por lo que puede obtenerse resultados óptimos para un horizonte de tiempo deseado.

Por estos motivos, el interés en la aplicación de MPC en la capa de gestión de energía aumentó en los últimos años. Los casos comúnmente planteados proponen soluciones para microrredes alejadas de la red de distribución (operación en modo aislado), las cuales integran paneles solares y baterías. En estos casos, la planificación del despacho es fundamental para el uso eficiente de la energía [13],[14]. Para planificar el despacho es recomendable conocer o estimar variables futuras. Por este motivo, el desarrollo de predictores de carga y de generación que sean confiables es importante para mejorar la performance del controlador MPC. El desarrollo de modelos de predicción está asociado a la naturaleza de la variable a predecir.

1.1.2 Gestión de sistemas de climatización

Hoy en día, los sistemas de climatización o sistemas HVAC (*heating, ventilation and air conditioning*) se han vuelto indispensables para el desarrollo de la vida humana desde distintos puntos de vista. Sus aplicaciones son diversas, como por ejemplo, brindar confort en residencias, mejorar la calidad del aire interior en centros médicos [15],[16] o incrementar la productividad en granjas avícolas [17]. Actualmente, estos sistemas están siendo muy estudiados por su alta demanda de potencia y su elevado consumo de energía. Se estima que la participación del consumo de equipos HVAC en edificios oscila entre el 40% y el 60% de la energía total y que además su consumo seguirá aumentando año tras año debido al incremento de la temperatura [18]. En este sentido, es deseable desarrollar estrategias tendientes a reducir su consumo y mejorar su operación, más aún, teniendo en cuenta que el 20% de las pérdidas energéticas se asocian a gestiones ineficientes [19].

La gestión de la demanda (*Demand Side Management, DSM*) y la respuesta a la demanda (*Demand Response, DR*) son estrategias aplicadas a cargas eléctricas para obtener beneficios, generalmente del tipo económico [20]. Las estrategias de DSM abarcan a las estrategias de DR, además de incorporar conceptos de eficiencia energética. En general, se pretende lograr el ajuste voluntario del consumo eléctrico del usuario para balancear generación con demanda, tanto en el corto como en el largo plazo [21]. Debido a que estos servicios facilitan el balance entre demanda y generación de manera rápida, son particularmente útiles en sistemas eléctricos con elevada penetración de energía renovable, donde la generación es fluctuante [22].

La aplicación de estrategias de DSM a sistemas HVAC puede reducir notablemente el consumo de energía sin perder el confort térmico [23]. Normalmente, los objetivos de control de estas estrategias persiguen la minimización del consumo de energía o del pico de demanda de los equipos HVAC, pero en otros casos se busca disminuir el monto de la factura de electricidad [24] o las emisiones de dióxido de carbono [25]. En sistemas con integración de energía renovable, también se busca maximizar su consumo, no solo para aprovechar la energía generada sino también para estabilizar el suministro [26].

1.1.3 Desafíos de los sistemas de protección en microrredes

Los sistemas de distribución tradicionales fueron diseñados para flujos de potencia unidireccionales, partiendo del paradigma de la generación concentrada, por lo que los esquemas de protección se desarrollaron para condiciones estáticas de activación y configuraciones radiales. En este contexto, las protecciones tradicionales funcionan por

sobrecarga y cortocircuito, basándose en relés que disparan interruptores de protección (CB, *circuit breaker*) cuando las corrientes superan un valor umbral preestablecido [27].

El advenimiento de la GD y de las MRs, particularmente con integración de generación renovable, introduce nuevos desafíos respecto a los sistemas de protección que surgen de las características de las corrientes de falla y de la bidireccionalidad de los flujos de potencia [28]. Las microrredes que integran GR tienen corrientes de fallas que varían en función de las condiciones de los recursos, como la radiación solar para la generación fotovoltaica, o la velocidad del viento en los aerogeneradores. Además, se basan en convertidores electrónicos que limitan la potencia durante la falla por lo que no se producen picos elevados y sostenidos de corriente, como sí sucede en sistemas basados en generadores sincrónicos (que por su elevada inercia pueden contribuir con hasta 6 veces su potencia nominal durante varios ciclos y luego decaer hasta el 200 %) [29]. Las características de las fallas también dependen del modo de funcionamiento del inversor durante el cortocircuito (*Fault Ride Through*) [28]. Por otro lado, las distintas topologías de conexión entre recursos distribuidos, o recursos distribuidos y red de distribución, implican flujos de potencia bidireccionales que dificultan la activación de las protecciones frente a fallas y facilitan las activaciones innecesarias (*sympathetic tripping* y *blinding*) [30]. Por estos motivos, las protecciones tradicionales no son efectivas en microrredes.

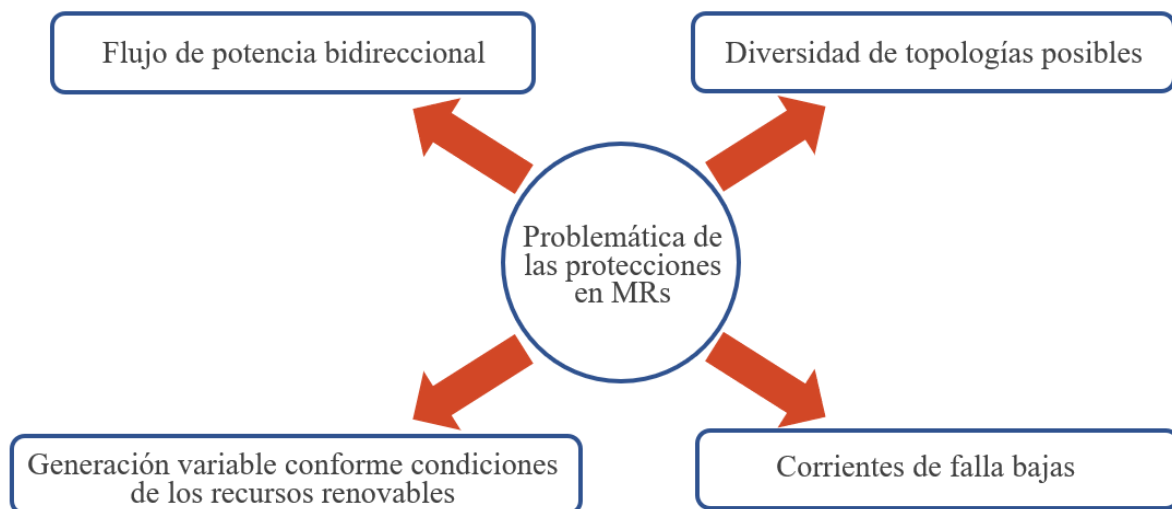


Figura 1.2. Principales problemáticas de los sistemas de protección de fallas en MRs.

Las características de las fallas en MRs dependen principalmente del modo en que operan, con conexión a la red de distribución o en modo isla, por lo que los desafíos de los sistemas de protección son distintos en cada caso. Cuando las MRs operan con conexión y se produce una falla, las corrientes de falla son elevadas debido a la contribución de la red de distribución,

facilitando la detección del evento. Por el contrario, en MRs aisladas, las corrientes de falla son mucho menores ya que solo dependen de las condiciones operativas de los recursos de energía distribuidos (radiación solar, velocidad del viento, estado de la carga de las baterías, etc.), lo que implica la necesidad de mayor sensibilidad en la detección [31].

La literatura de sistemas de protección de fallas asociados a microrredes puede clasificarse en dos grandes grupos. Por un lado, un grupo que aborda los efectos de la conexión de MRs en sistemas de distribución (aguas arriba de las MRs), y por otro, un segundo grupo que estudia métodos de protección dentro de las MRs (aguas abajo del punto de conexión con la red). Este último grupo puede subclasificarse de acuerdo a la arquitectura de la MR, es decir si es de corriente continua (DC), de alterna (AC) o híbrida; si es monofásica o trifásica; o conforme el modo de operación, con conexión a red o modo isla.

1.2 Organización y estructura de la Tesis

Esta Tesis desarrolla distintos esquemas teóricos como posibles soluciones a las problemáticas que las MRs tienen hoy en día, de manera de facilitar su implementación real. En concreto, se hace foco en las estrategias de gestión de energía, tanto del lado de la carga como de la generación, y en los sistemas de protección, particularmente para MRs DC. Por otro lado, se incorpora también un capítulo práctico donde se desarrolla el trabajo de campo realizado para poner en marcha un pequeño parque solar en Entre Ríos, llevado a cabo en el marco de la Tesis doctoral.

La Tesis se compone por un total de 6 capítulos. El Capítulo 1 y el Capítulo 6 son la introducción y las conclusiones generales de la Tesis, respectivamente. Los Capítulos 2, 3, 4 y 5, son autocontenidos y estructuralmente se asocian a un artículo científico publicado o por publicarse. Por este motivo, cada uno de estos capítulos presenta su propio resumen, introducción, contribución científica, desarrollo metodológico, resultados y discusión.

Los Capítulos 2 y 3 desarrollan estrategias de gestión de energía con distintos enfoques, pero ambos incluyen la gestión de equipos de climatización. El Capítulo 2, propone una estrategia para gestión de equipos HVAC dentro de un esquema de respuesta a la demanda de una distribuidora de energía, basándose en un controlador predictivo, en el desarrollo de un modelo térmico y en la evaluación del confort mediante el voto medio estimado. Esta estrategia se aplica al sistema HVAC de un centro médico en Entre Ríos. Por otro lado, el Capítulo 3 propone la integración de estrategias de gestión de la demanda, aplicadas a equipos HVAC, y de despacho óptimo de distintos generadores bajo la misma formulación de un controlador

MPC. Se abordan dos MRs de estudio que representan casos de interés regional: la primera, una granja avícola funcionando aislada de la red, y la segunda, el centro de salud descrito en el capítulo anterior.

Por otro lado, en el Capítulo 4 se propone un método de detección, identificación, localización y aislación de fallas para MRs DC basado en modelo y en comunicación. Se desarrollan dos modelos de falla, uno para cortocircuitos y otro para circuitos abiertos, describiendo también el funcionamiento del algoritmo de protección. Por último, se evalúa el esquema de protección en el bus DC de la MR aislada expuesta en el Capítulo 3.

El Capítulo 5, a diferencia de los mencionados anteriormente, tiene un enfoque práctico dado que aborda las etapas de diseño, simulación, análisis, instalación y puesta en marcha de una planta de generación fotovoltaica en una granja avícola de Entre Ríos. Se pone en contexto el proyecto dentro del nuevo marco legal de la provincia, vigente a partir del año 2023, que fomenta la utilización de recursos renovables en la generación de electricidad. La evaluación tecno-económica del proyecto se lleva a cabo mediante el software HOMER Pro®, por lo que se describen sus funcionalidades y también algunos conceptos económicos básicos para el análisis de proyectos. Por último, se analizan los resultados obtenidos durante el período de funcionamiento de la instalación fotovoltaica (período comprendido entre el 1° de febrero del 2023 al 1° de febrero del 2024) y se los compara con dos casos hipotéticos: la misma granja sin generación fotovoltaica, y la misma granja con instalación fotovoltaica, pero adicionalmente con la implementación de una gestión de energía ideal.

La estructura general de la Tesis se sintetiza en la Figura 1.3. Los bloques celestes se asocian a información general, los grises representan los esquemas o métodos desarrollados, y los amarillos, los casos de aplicación.

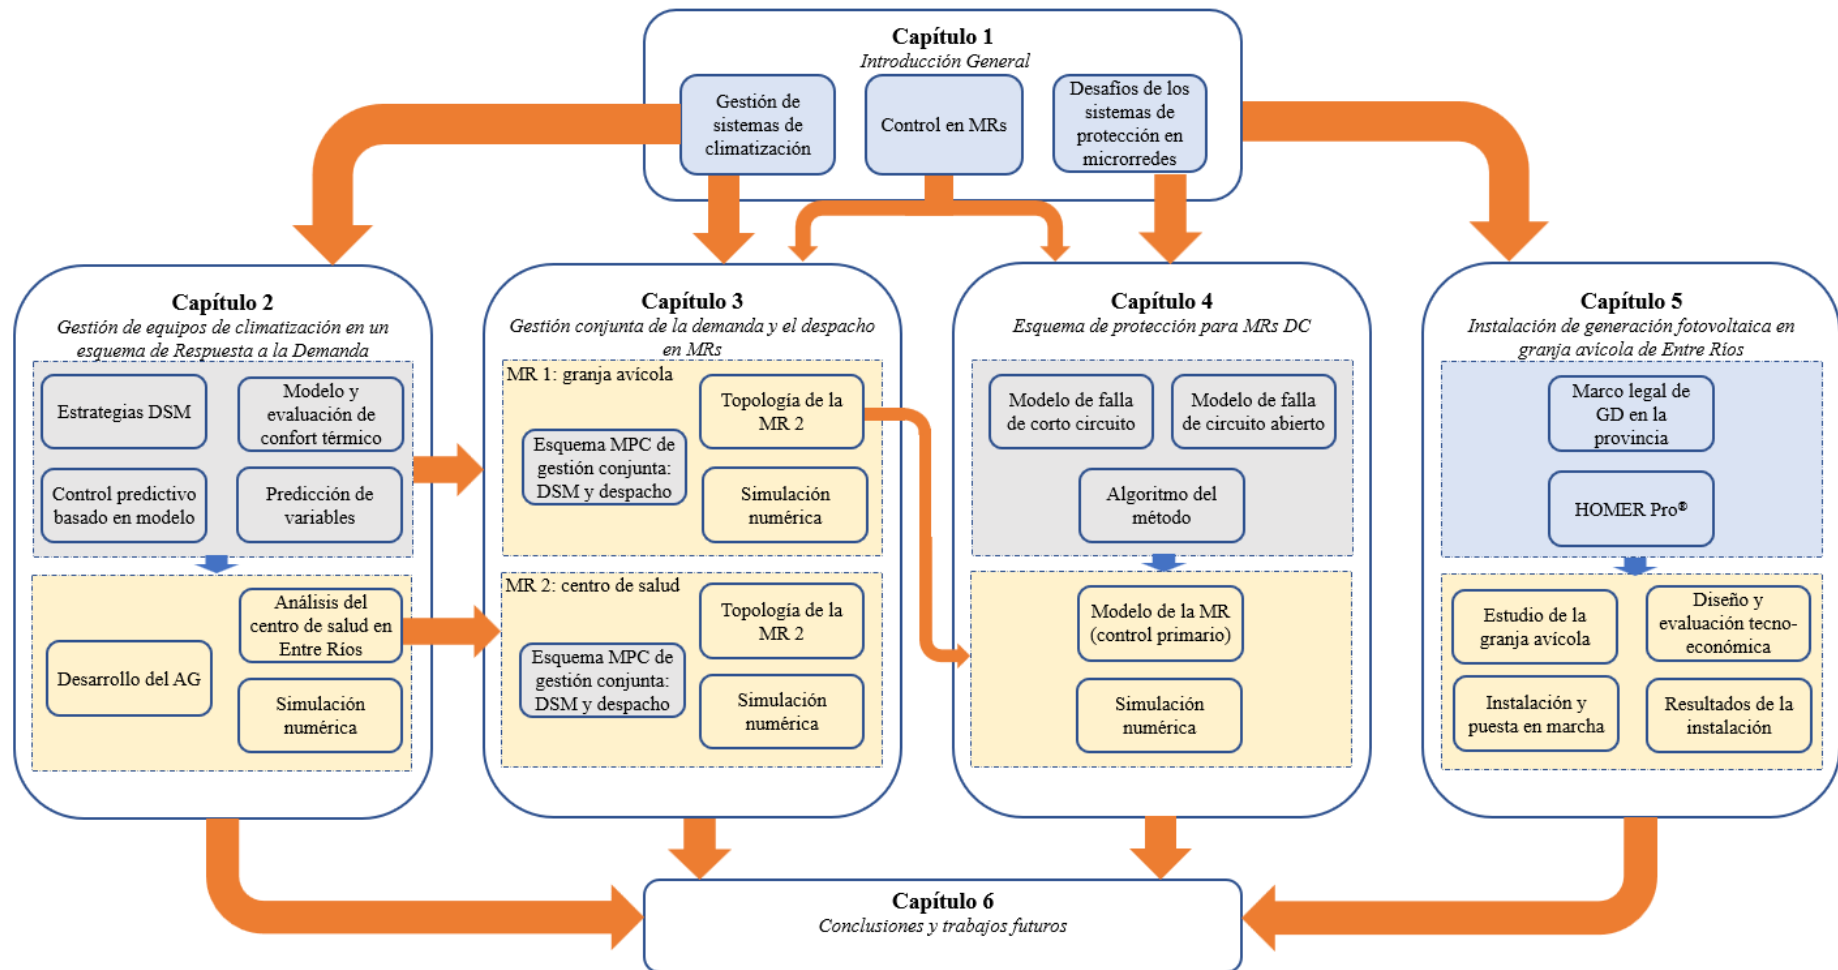


Figura 1.3. Estructura de la Tesis.

Capítulo 2

GESTIÓN PREDICTIVA EN TIEMPO REAL DE SISTEMAS DE CLIMATIZACIÓN BASADA EN OPTIMIZACIÓN HEURÍSTICA

2.1 Resumen del capítulo

Los sistemas de climatización tienen elevada demanda de potencia y gran consumo de energía por lo que el desarrollo de estrategias eficientes de control puede resultar en una disminución del consumo y una mejora del confort térmico. En este capítulo se propone un esquema de gestión predictiva en tiempo real de equipos de climatización integrados por múltiples unidades, aplicable a edificios multi-zonas, y con un bajo costo de implementación. Se basa en un control predictivo que busca maximizar el confort térmico y minimizar el costo asociado al consumo de energía eléctrica. La evaluación del confort térmico en la función costo se lleva a cabo mediante el voto medio estimado, definido en la norma ISO 7730, que incorpora alinealidades en su cálculo. Por este motivo, el problema de optimización se resuelve con un enfoque heurístico. Se utilizan modelos simples de predicción de variables como temperatura exterior, ocupación de salas y demanda de carga. Estos modelos se desarrollan mediante reconciliación de nivel con perfiles promedios generados a partir de datos históricos. El esquema se aplica al caso de estudio de un sistema de climatización de un centro de salud en Entre Ríos. El desempeño de la estrategia se evalúa en diferentes casos, utilizando modelos de predicción de variables, predicción perfecta y diferentes horizontes de predicción (de 1, 2 y 3 horas). Además, se compara la estrategia con un control por banda de temperatura (encendido y apagado), con y sin recorte de picos, demostrando que la estrategia propuesta mejora el confort térmico (hasta un 47%) y obtiene un bajo costo en la factura eléctrica, en particular en comparación con la estrategia sin recorte de pico (disminución del 23%).

2.2 Introducción

El consumo energético en edificios equivale al 30% del consumo total de energía y al 26% de las emisiones globales de dióxido de carbono en todo el mundo [32]. Los sistemas de climatización o HVAC consumen entre el 40% y el 60% del total de energía en los edificios [33]. Por esta razón, la tecnología de los equipos HVAC ha mejorado considerablemente en los últimos años. Sin embargo, su control inadecuado puede causar ineficiencias [34] además de generar pérdida en el confort de las personas [35]. Los centros de salud son casos de interés

particular, dado que tienen un elevado consumo de energía en climatización por su funcionamiento continuo, por los requerimientos de confort térmico y por los requisitos calidad ambiental interior [36]. El confort térmico es el estado en el cual el balance de calor entre el cuerpo y el entorno se encuentra en equilibrio. En este sentido, existen diferentes modelos para cuantificarlo, siendo el voto medio estimado (*Predicted Mean Vote*, PMV) el más adoptado [37].

Gestionar los sistemas HVAC para reducir el consumo de energía y aumentar el confort térmico son objetivos que en principio presentan cierto antagonismo. Sin embargo, una estrategia apropiada de gestión de la demanda puede alcanzar ambos objetivos simultáneamente [33]. Las estrategias de DSM surgieron como solución al aumento del consumo de energía eléctrica a nivel mundial. Se basan en la modificación de la demanda de las cargas y/o en el desplazamiento de su operación de manera que el suministro sea mejor aprovechado [38]. Las estrategias de DR forman parte de la gestión de la demanda, y buscan alentar a los usuarios a cambiar sus comportamientos de consumo utilizando señales de precios o esquemas tarifarios [39].

El confort térmico es un parámetro muy importante en cuanto a calidad ambiental interior en centros de salud [40]. Dado los requisitos de confort, los sistemas HVAC representan una parte significativa del consumo en instalaciones médicas [41]. Por otro lado, los equipos de mayor demanda, como los utilizados para llevar a cabo estudios y tratamientos, funcionan mediante turnos de pacientes, lo que facilita la predicción de la carga. Esta característica facilita la aplicación de estrategias de DSM como desplazamiento de carga.

En Argentina, las distribuidoras eléctricas establecen un esquema tarifario para grandes usuarios con diferentes costos horarios de potencia y energía (*time of use*, TOU). Además, las distribuidoras en general aplican una tarifa de energía considerablemente superior a usuarios que superan los 300 kW de potencia solicitada a la red. Esta tarifa encarecida, se aplica a los cuatro meses siguientes a partir de que la potencia contratada se actualiza con la demandada. Esto motiva el desarrollo de estrategias de DSM que permitan modificar los hábitos de consumo de manera de mejorar la eficiencia de los sistemas HVAC y reducir costos, especialmente en aquellos usuarios con demandas cercanas a los 300 kW [42].

El control predictivo basado en modelo o MPC es adecuado para desarrollar esquemas de DSM o DR. Esta técnica avanzada de control permite mejorar la gestión de equipos HVAC

mediante la resolución de un problema de optimización de horizonte deslizante, minimizando una función costo y teniendo en cuenta las restricciones físicas/operativas del sistema [43].

2.2.1 Antecedentes

El interés científico en la gestión y control de sistemas HVAC ha crecido notablemente en los últimos años, especialmente para aplicaciones residenciales. En la literatura se identifican dos grupos de trabajos que abordan la gestión de climatización:

- i) Aquellos que se enfocan en la planificación y programación de la operación de equipos HVAC, generalmente formulados como un problema de optimización resuelto mediante programación matemática o algoritmos heurísticos;
- ii) Aquellos que proponen la gestión en tiempo real, utilizando control basado en reglas, control on/off, MPC o aprendizaje maquina.

Se observa que muchos trabajos actuales proponen la integración de gestión de equipos HVAC con generación renovable y sistemas de almacenamiento. En general, se pretende mejorar el confort térmico y reducir al mínimo la demanda de potencia a la red de distribución. A menudo se utiliza el software EnergyPlusTM o algoritmos basados en aprendizaje maquina para modelar los sistemas de climatización como una caja negra. Otros trabajos utilizan modelos térmicos análogos a circuitos resistivos-capacitivos (RC) simples, como una caja gris, pero pocos consideran los efectos térmicos que una sala produce sobre otra contigua. Por otro lado y en general, el confort térmico se evalúa a partir de la desviación entre temperatura medida y temperatura deseada [44].

El control MPC presenta ventajas sobre otros métodos para desarrollar estrategias de DSM en tiempo real. Este esquema de control puede lidiar con perturbaciones e incertidumbres, considerar restricciones físicas y operativas, utilizar predicciones de la demanda y principalmente basar su funcionamiento en el comportamiento futuro del sistema [4]. Esto permite tomar acciones de control que a priori no serían óptimas en un momento determinado, pero que resultan buenas al considerar un horizonte temporal. Además, es posible incluir funciones costo multiobjetivo en la formulación del controlador, permitiendo considerar objetivos económicos, de confort y de control en simultaneo. El MPC permite desarrollar programas de DR aplicados a equipos HVAC utilizando modelos térmicos, predicciones de la temperatura externa e incluir restricciones en la demanda. Su utilización en estas aplicaciones ha crecido en los últimos tiempos debido al incremento de la capacidad computacional de los sistemas de automatización [45].

Los trabajos más relevantes relacionados con la propuesta de este capítulo, se resumen en la Tabla 2.1. Los autores de [46] se centran en el desarrollo de un sistema óptimo de gestión de energía térmica en tiempo real (TEMS) para hogares inteligentes que responde a programas de DR para desplazar la carga del pico. El TEMS propuesto combina dos controladores predictivos basados en modelos para gestionar dos sistemas de almacenamiento de energía térmica y programar la operación de una bomba de calor residencial en períodos de demanda baja. El objetivo es minimizar el consumo total de energía y el costo económico, manipulando el volumen y la temperatura del agua almacenada en un tanque mientras se optimiza la operación de distribuidores de calor para controlar la temperatura interior. La gestión térmica se realiza en una sola zona, no se considera la ganancia de calor interior (*internal heat gain*, IHG) y utiliza programación lineal entera mixta (*Mixed Integer Linear Problems*, MILP) en la optimización. En [47], se propone un control predictivo de un solo aire acondicionado tipo *split* que determina el *setpoint* de temperatura minimizando el error cuadrático entre el PMV deseado y el obtenido, considerando simplificaciones para utilizar programación cuadrática (*quadratic programming*, QP) y sin considerar la factura de energía en la función de costo. El modelo térmico se desarrolla con EnergyPlusTM y la representación de espacio de estados se obtiene con el método subspace N4SID de MATLAB. Otro trabajo propone un MPC centralizado para minimizar el costo de energía y mejorar el confort, considerando el uso de paneles fotovoltaicos (*photovoltaic*, PV) y baterías [48]. El MPC controla la potencia de la bomba de calor y de un calefactor eléctrico para gestionar el confort y el flujo de potencia entre el PV, la batería y la red. La función costo evalúa el confort penalizando desviaciones de temperatura con respecto a una temperatura deseada. El modelo térmico se desarrolla en TRNSyS. Los autores de [49] desarrollan un control predictivo que busca mantener el confort térmico de un edificio multi-zona mientras reduce los picos de potencia demandada. Para tal fin, el controlador gestiona el sistema HVAC además de los dispositivos de almacenamiento y generación renovable, basándose en una optimización multiobjetivo que considera el costo de energía y el confort térmico. El costo de energía se evalúa mediante un costo virtual que busca desalentar soluciones en las que los equipos HVAC de diferentes zonas funcionen en simultáneo. El confort térmico se evalúa a través del porcentaje predicho de insatisfacción. El controlador determina la potencia de la batería y de la red, además de proporcionar un control de confort indirecto mediante el ajuste de temperatura en cada sala. Utiliza un modelo análogo simple RC que no considera el IHG. Los autores de [50] desarrollan tres estrategias de control, considerando un horizonte de una hora, para un edificio de un campus universitario modelado

Paper	Predicción	Actuación	Horizonte	Control / optimización	Objetivos	Modelo térmico	Confort	Tipo de edificio	IHG	Variable de control
[46]	Perfecta	Tiempo real	24 h	MPC / MILP	Factura eléctrica y confort	Thermal equations	Desviación de temperatura	Laboratorio – Una zona	No	Setpoint de temperatura
[47]	No usa	Tiempo real	10 min	MPC / QP	Reducir consumo	EnergyPlus	PMV	Residencial – Una zona	Sí	Setpoint de temperatura
[48]	Perfecta con ruido agregado	Tiempo real	8 h	MPC / fmincon	Factura eléctrica y confort	TRNSYS - MATLAB	Temperature difference and zone	Residencial – Multizona (centralizado)	Sí	Setpoint de temperatura
[49]	Perfecta	Tiempo real	24 h	MPC / QP	Factura eléctrica y confort	Análogo RC	PMV	Educación - Multizona	Sí	Setpoint de temperatura
[50]	ANN	Tiempo real	1 h	MPC - SMC	Consumo y confort	EnergyPlus	PMV	Campus universitario – Multizona	Sí	Setpoint de temperatura
[51]	No menciona	Tiempo real	9 h	MPC	Consumo y confort	EnergyPlus	PMV	Oficina - Multizona	Sí	Setpoint de temperatura
[18]	EnergyPlus	Próximo día	8 h / 24 h	MPC / AG	Consumo y confort	EnergyPlus	PMV	Oficina - Multizona	Sí	Setpoint de temperatura
[52]	No menciona	No menciona	No menciona	MPC / PSO modificado	Consumo y confort	EnergyPlus	PMV	Comercial - Una zona	No menciona	Setpoint de temperatura
[53]	Si, pero no dice cómo	Próximo día	24 h	MPC / PSO	Reducir pico de demanda	RC complejo	No	Residencial – Una zona	Sí	Setpoint de temperatura
[42]	Perfecta	Próximo día	24 h	AG	Factura eléctrica y confort	Análogo RC (espacio de estados discreto)	PMV	Médico – Multizona	Sí	Estado de unidades HVAC
Esta gestión	Reconciliación de nivel	Tiempo real	1 h	MPC/ AG	Factura eléctrica y confort	Análogo RC (espacio de estados discreto)	PMV	Médico - Multizona	Sí	Estado de unidades HVAC

Tabla 2.1. Comparación del esquema propuesto con trabajos similares.

en EnergyPlusTM. Las estrategias se basan en MPC, en control de modo deslizante (SMC) y en control simple de encendido/apagado, buscando reducir el consumo energético mientras se maximiza el confort, evaluado mediante el PMV. Otro trabajo propone una estrategia de MPC para el control de confort y el consumo de energía del sistema de aire acondicionado de un complejo de oficinas, utilizando el PMV para cuantificar el confort [51]. El modelo térmico se desarrolla en EnergyPlusTM, mientras que la optimización se programa con un algoritmo de búsqueda exhaustiva en MATLAB. En [18] se propone un MPC para reducir costos y aumentar el confort, utilizando EnergyPlusTM como modelo detallado y un algoritmo genético (AG) para la optimización. Debido a la complejidad del problema, se realiza una optimización en dos etapas, utilizando 40 núcleos. A pesar de esto, el problema propuesto tarda más de una hora en converger, por lo que las acciones de control deben calcularse con una hora de anticipación.

Pocos trabajos proponen algoritmos heurísticos para resolver el problema de optimización del MPC. En [52], un controlador MPC determina el *setpoint* de temperatura utilizando una optimización de enjambre de partículas (PSO) Hooke-Jeeves que incorpora restricciones de temperatura, costos térmicos y energéticos. El controlador utiliza la masa térmica del edificio para reducir el costo de energía y mantener el confort térmico, que se evalúa a través del PMV. El modelo térmico se desarrolla en EnergyPlusTM y se enlaza con el algoritmo heurístico utilizando GenOpt. Otra investigación también utiliza un PSO mejorado con lista tabúes para resolver la optimización de un MPC de horizonte deslizante distribuido. El controlador determina el *setpoint* óptimo de temperatura dentro de un rango dado según la hora del día, minimizando la demanda a red, pero sin tener en cuenta el confort térmico [53]. El trabajo investiga la potencialidad de los edificios residenciales para incrementar el factor de carga de las distribuidoras de energía al utilizar el controlador desarrollado de manera masiva. En este sentido, el controlador no está formulado para brindar un beneficio económico ni de confort a los usuarios.

2.2.2 Motivación

La literatura analizada muestra que las oportunidades de investigación incluyen el desarrollo de estrategias de gestión HVAC para edificios industriales/comerciales (las aplicaciones residenciales son las más exploradas) y el desarrollo de estrategias para sistemas HVAC multi-unidades descentralizados y/o en edificios multi-zonas. En general, la mayoría de los trabajos utilizan modelos térmicos simplificados o utilizan EnergyPlusTM. El confort térmico se evalúa como la desviación de la temperatura deseada con la obtenida, para que el problema de

optimización sea lineal y pueda utilizarse programación matemática. De igual manera, los procesos termodinámicos no lineales suelen modelarse como sistemas lineales e invariantes en el tiempo (LTI), y las funciones objetivo de dichos sistemas se resuelven principalmente mediante algoritmos de programación lineal (LP) y programación cuadrática (QP) [54].

Para el control de los equipos HVAC, la mayoría de los trabajos proponen gestionar el rango de temperatura de los termostatos. En menor medida, proponen un control indirecto a través de la manipulación de la potencia de los equipos HVAC, considerándola como una variable continua. El uso de EnergyPlus™ para desarrollar el modelo térmico proporciona resultados muy precisos, pero implica largos tiempos en la resolución del problema de optimización y la necesidad de una computadora para la ejecución del software. Esto dificulta su uso en aplicaciones en tiempo real y de bajo costo.

2.2.3 Contribución

Se propone un esquema de gestión para sistemas de climatización multi-unidades y multi-zonas que coordina, en tiempo real, la operación de los equipos de manera de minimizar el costo de energía eléctrica y maximizar el confort térmico. El esquema se basa en un control predictivo heurístico que incorpora un modelo térmico y modelos de predicción de temperatura exterior, IHG (generado por personas, luces, dispositivos, etc.) y demanda de las cargas. Se desarrolla un modelo térmico multi-zona a partir de un circuito equivalente RC que contempla la interacción entre salas contiguas y los efectos de las fuentes internas de calor. La función costo multiobjetivo está compuesta por el costo de energía eléctrica de la distribuidora y el confort térmico, evaluado mediante el PMV. El problema de optimización se formula para ser resuelto con un enfoque heurístico.

Este método se diferencia de la literatura descrita anteriormente en que gestiona, en tiempo real, los estados (encendido o apagado) de múltiples unidades HVAC que funcionan en bloque. En este sentido, la variable de control es el estado de los equipos HVAC en vez del *setpoint* de temperatura o la potencia de los equipos. Además, incorpora modelos de predicción de perturbaciones y de demanda de la carga para llevar a cabo la gestión de manera óptima. Como principal contribución, la estrategia posee baja demanda computacional, por lo que es útil en implementaciones de bajo costo.

Además, se desarrolla un algoritmo genético para aplicar el esquema en el caso de estudio de un centro de salud (CS) ubicado en Entre Ríos. La estrategia desarrollada se compara con

un control por banda de temperatura para múltiples unidades HVAC, obteniendo mejoras sustanciales.

2.3 Metodología

2.3.1 Gestión de la demanda

La DSM se compone de un conjunto de herramientas que permite mejorar la eficiencia de los sistemas de potencia. En esencia, se busca que el perfil de la demanda siga al de generación para aumentar el factor de carga, lo cual es sumamente deseable en sistemas con alta penetración de energía renovable [20].

Las estrategias de DSM pueden llevarse a cabo de manera directa o indirecta [55]. En gestión directa, las distribuidoras controlan las cargas de los usuarios, mientras que en la indirecta los usuarios son quien gestionan las cargas de manera independiente o a través de señales de precio. Las principales estrategias de DSM son (ver Figura 2.1) [22]:

- Recorte de picos (RP): es la estrategia más simple dado que consisten en apagar las cargas cuando se alcanza un umbral de potencia determinado.
- Llenado de valles: mejora el factor de carga a partir de aumentar la carga en momentos de demanda baja.
- Corrimiento o desplazamiento de carga: reducción de la carga durante el pico de demanda en simultáneo con la habilitación de carga durante períodos de menor demanda. Esta estrategia requiere que las cargas sean controlables.
- Crecimiento estratégico: aumento de la carga a lo largo del día mediante el aumento del consumo total.
- Conservación estratégica: reducción de la carga a lo largo del día mediante el uso de dispositivos más eficientes o mediante la reducción del consumo total.
- Carga flexible: contratos y tarifas específicas con la posibilidad de controlar de manera flexible los equipos del usuario (gestión directa).

La DR implica la planificación e implementación de políticas por parte de la distribuidora eléctrica y los operadores de la red, para influir en el comportamiento del consumidor [56]. Por ejemplo, desplazar la demanda de horas pico a horas fuera de pico.




Figura 2.1. Principales estrategias de gestión de la demanda [57].

En Argentina, los proveedores de energía a menudo utilizan esquemas tarifarios TOU (por bandas horarias) para influir en el consumo de los grandes usuarios de energía.

En este capítulo, se propone la gestión de unidades HVAC, bajo un esquema de DR, que resulta de la combinación de desplazamiento de carga y conservación estratégica. Esta gestión, formulada como un problema de optimización de horizonte deslizante, desplaza temporalmente y/o reduce la demanda de las unidades HVAC de acuerdo a una función objetivo que considera el confort térmico y el monto de la factura eléctrica.

2.3.2 Modelo térmico

Se desarrolla un modelo térmico análogo a un circuito eléctrico resistivo-capacitivo (RC) que considera la interacción térmica entre salas contiguas (modelo multi-zona) y los efectos producidos por las fuentes de calor internas (personas, iluminación, equipamiento, etc.). La Figura 2.2 muestra este modelo para dos salas, con el equipo de climatización funcionando como refrigerador. T_e es la temperatura exterior del edificio, T_{i1} , T_{i2} son las temperaturas interiores de las salas 1 y 2, respectivamente. P_{th1} es la potencia térmica del equipo HVAC y P_{s1} es la potencia térmica producida por fuentes de calor internas en la sala 1 (como personas, iluminación y equipos). Las potencias térmicas (P_{te}) y eléctricas (P_{hvac}) de un equipo HVAC están relacionadas por $P_{th} = \eta P_{hvac}$, siendo η es el coeficiente de rendimiento (*coefficient of performance*, CoP). R_1 y R_2 son las resistencias térmicas de las paredes independientes de las salas 1 y 2, y R_{12} es la resistencia térmica de la pared compartida. C_1 y C_2 son las capacidades térmicas de las salas y representan su capacidad de absorción de calor.

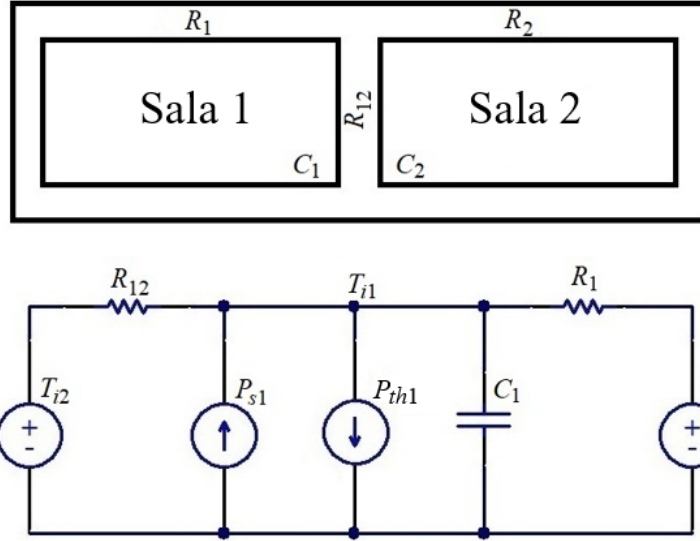


Figura 2.2. Arriba: diagrama de salas contiguas. Abajo: modelo RC equivalente (refrigeración de la sala 1).

El balance de corriente del circuito de la Figura 2.2 está dado por (2.1):

$$C_1 \frac{dT_{i1}}{dt} = -P_{th1} + P_{s1} + \frac{(T_e - T_{i1})}{R_1} + \frac{(T_{i2} - T_{i1})}{R_{12}} \quad (2.1)$$

La ecuación anterior puede ser reescrita de la siguiente manera:

$$\frac{dT_{i1}}{dt} = \alpha_{11} T_{i1} + \alpha_{12} T_{i2} + \beta_1 P_{hvac1} + d_1 \quad (2.2)$$

donde:

$$\alpha_{11} = -\frac{1}{C_1} \left(\frac{1}{R_1} + \frac{1}{R_{12}} \right), \alpha_{12} = \frac{1}{R_{12} C_1}, \beta_1 = -\frac{\eta}{C_1} \text{ y } d_1 = \frac{1}{C_1} \left(P_{s1} + \frac{T_e}{R_1} \right) \quad (2.3)$$

De igual manera, se obtiene la ecuación asociada a la sala 2:

$$\frac{dT_{i2}}{dt} = \alpha_{22} T_{i2} + \alpha_{21} T_{i1} + \beta_2 P_{hvac2} + d_2 \quad (2.4)$$

donde:

$$\alpha_{22} = -\frac{1}{C_2} \left(\frac{1}{R_2} + \frac{1}{R_{12}} \right), \alpha_{21} = \frac{1}{R_{12} C_2}, \beta_2 = -\frac{\eta}{C_2} \text{ y } d_2 = \frac{1}{C_2} \left(P_{s2} + \frac{T_e}{R_2} \right) \quad (2.5)$$

Por lo tanto, la representación de espacio de estados continua del circuito equivalente RC es:

$$T_i' = A \cdot T_i + B \cdot P_{\text{hvac}} + D \cdot d \quad (2.6)$$

siendo T_i , P_{hvac} y d los vectores de temperaturas interiores (variables de estado), potencias eléctricas de las unidades HVAC (variables manipuladas) y perturbaciones (temperatura exterior y calor emitido por fuentes de calor internas), respectivamente. Las matrices A, B y D son:

$$A = \begin{bmatrix} \alpha_{11} & \alpha_{12} \\ \alpha_{21} & \alpha_{22} \end{bmatrix}, \quad B = \begin{bmatrix} \beta_1 & 0 \\ 0 & \beta_2 \end{bmatrix} \quad \text{y} \quad D = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

La representación de espacio de estados discreto se obtiene considerando un retenedor de orden cero con un período de muestreo t_s , obteniendo (2.7). El subíndice d indica que las matrices están expresadas en sus formas discretas.

$$T_i(k+1) = A_d T_i(k) + B_d P_{\text{hvac}}(k) + D_d d(k) \quad (2.7)$$

Este modelo puede ser extendido a edificios con diferentes disposiciones y cantidad de salas.

2.3.3 Confort térmico

La norma ISO 7730 propone el uso del voto medio estimado (*predictive mean vote, PMV*) como métrica para evaluar sensación térmica [58]. Este índice utiliza el balance de calor del cuerpo humano para determinar el confort de los ocupantes de una sala en una escala de siete puntos. Los valores positivos de *PMV* indican una sensación de calor, los negativos indican una sensación de frío y un *PMV* igual a cero indica el máximo confort, como se muestra en la Figura 2.3.




Figura 2.3. Escala del *PMV*.

El valor del *PMV* depende de varios factores, algunos de los cuales se calculan de manera iterativa [58]. El valor del *PMV* se calcula según (2.8).

$$\begin{aligned}
PMV = & (0.303e^{-0.036M} + 0.028) \{ (M - W) - 3.05 \cdot 10^{-3} [5733 - 6.99(M - W) - p_a] \\
& - 0.42[(M - W) - 58.15] - 1.7 \cdot 10^{-5} M(5867 - p_a) - 0.0014M(34 - T_a) \\
& - 3.96 \cdot 10^{-8} f_{cl} [(T_{cl} + 273)^4 - (T_r + 273)^4] - f_{cl} h_c (T_{cl} - T_a) \}
\end{aligned} \tag{2.8}$$

donde M es la tasa de metabolismo (W/m^2), W es la potencia mecánica efectiva (W/m^2), p_a es la presión parcial de vapor de agua (Pa), T_a es la temperatura del aire ($^{\circ}C$), T_{cl} es la temperatura superficial de la ropa ($^{\circ}C$), T_r es la temperatura radiante media ($^{\circ}C$), f_{cl} es el factor de área superficial de la ropa y h_c es el coeficiente de transferencia de calor convectivo [$W/(m^2K)$].

El factor de superficie de la ropa (f_{cl}), la temperatura superficial de la ropa (T_{cl}) y el coeficiente de transferencia de calor convectivo (h_c) se calculan (de manera iterativa para T_{cl} y h_c), según (2.9), (2.10) y (2.11), respectivamente.

$$f_{cl} = \begin{cases} 1.00 + 1.290 I_{cl} & \text{para } I_{cl} \leq 0.078 \text{ m}^2\text{K/W} \\ 1.05 + 0.645 I_{cl} & \text{para } I_{cl} > 0.078 \text{ m}^2\text{K/W} \end{cases} \tag{2.9}$$

$$T_{cl} = 35.7 - 0.028(M - W) - I_{cl} \{ 3.96 \cdot 10^{-8} f_{cl} [(T_{cl} + 273)^4 - (t_r + 273)^4] + f_{cl} h_c (T_{cl} - T_a) \} \tag{2.10}$$

$$h_c = \begin{cases} 2.38 |T_{cl} - T_a|^{0.25} & \text{para } 2.38 |T_{cl} - T_a|^{0.25} > 12.1 \sqrt{v_{ar}} \\ 12.1 \sqrt{v_{ar}} & \text{para } 2.38 |T_{cl} - T_a|^{0.25} < 12.1 \sqrt{v_{ar}} \end{cases} \tag{2.11}$$

Siendo I_{cl} es la resistencia térmica de la ropa (m^2K/m) y v_{ar} es la velocidad relativa del aire (m/s).

Mediante estimaciones y suposiciones comúnmente adoptadas, el PMV puede definirse en función de la temperatura interior del aire de la sala [42]. Sin embargo, en el esquema propuesto se considera la temperatura del aire interior (T_i), la humedad relativa (RH) y la velocidad del aire interior (v_a) como variables del PMV , es decir, $PMV = f(T_i, RH, v_a)$. Las variables restantes se estiman y se consideran constantes durante el horizonte de predicción utilizado en la resolución del problema de optimización. La temperatura radiante media se considera igual a la temperatura del aire [59], [60], [61] debido a simplificaciones del modelo RC propuesto [9],[31]. La ecuación de predicción utilizada para la humedad relativa es (2.12) [63]:

$$RH(k+1)=RH(k) \frac{e^{\frac{17.502T_i(k)}{240.97+T_i(k)}}}{e^{\frac{17.502T_i(k+1)}{240.97+T_i(k+1)}}} \quad (2.12)$$

En este esquema se propone un criterio basado en el valor absoluto del PMV para evaluar el confort térmico. El valor absoluto permite cuantificar tanto desviaciones positivas como negativas del PMV respecto al valor ideal ($PMV=0$), en concordancia con la simetría de la escala (Figura 2.3). Para el caso de un edificio de m salas, puede asumirse que el costo de confort térmico (C_{th}) es la suma de los costos térmicos de todas las salas, evaluados a través del PMV de cada una y en cada instante k :

$$C_{th}(PMV(k)) = \sum_{r=1}^m c_r |PMV_r(T_{i_r}(k), RH_r(k), v_{a_r}(k))| \quad (2.13)$$

donde c es un vector que permite ponderar el confort de la sala r (subíndice) para establecer un esquema de prioridad térmica. PMV es un vector que contiene el PMV de cada una de las salas. Se concluye que el máximo confort se logra cuando $C_{th} = 0$.

2.3.4 Control Predictivo basado en Modelo (MPC)

El MPC es una de las estrategias de control avanzado más utilizadas en la industria, ya que proporciona un enfoque intuitivo para el control óptimo de un sistema o proceso con restricciones. La Figura 2.4 muestra un esquema simplificado de un MPC. Su mecanismo básico consiste en predecir la evolución futura del sistema utilizando un modelo y variables medidas (pasadas y presentes) de manera de calcular acciones óptimas de control (posibles entradas del sistema) para un horizonte dado. En cada intervalo de muestreo, comenzando desde el estado actual, se formula y resuelve un problema de optimización a lo largo de un horizonte finito para lograr la operación esperada del sistema, determinando la mejor secuencia factible de entradas. El resultado de la optimización es una secuencia de señales de control presentes y futuras para alimentar el sistema satisfaciendo sus restricciones. Se inyecta en el sistema únicamente la primera señal de control determinada por el MPC, mientras que el resto de la secuencia se descarta. Este proceso se repite de manera iterativa en cada horizonte deslizando, basado en los estados actualizados [64], [65].

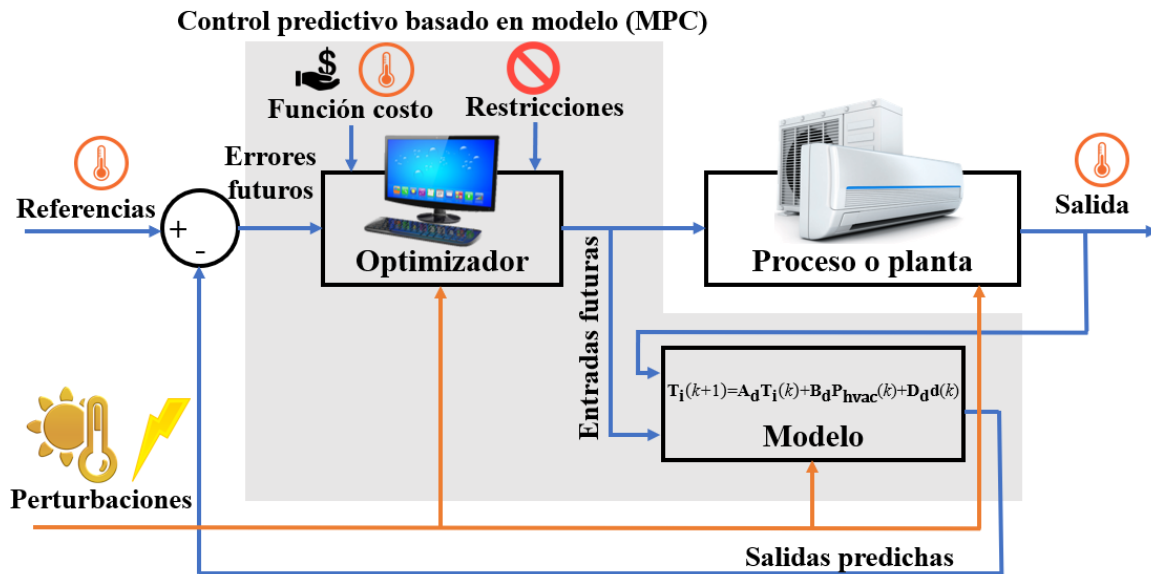


Figura 2.4. Diagrama esquemático de un MPC [66].

En este capítulo se propone un esquema basado en MPC que utiliza una función costo multiobjetivo. En particular, el objetivo del controlador es determinar las acciones P_{hvac} (vector que contiene la potencia de los equipos HVAC en cada sala) que minimizan la función costo para un horizonte temporal y que está sujeta a un conjunto de restricciones, en cada instante k . El problema de optimización se formula para ser resuelto con un enfoque heurístico. Esto se debe a que la temperatura de superficie de la ropa y el coeficiente de transferencia de calor convectivo, necesarios para determinar el PMV , se calculan de manera iterativa según la norma ISO 7730. En este sentido, los algoritmos heurísticos pueden resolver funciones costo altamente complejas con diferentes tipos de restricciones, proporcionando soluciones subóptimas pero aceptables para muchos problemas de ingeniería.

A. Función costo

La función costo debe representar los objetivos de control, que pueden ser minimizar el consumo de energía o la demanda de energía de la red, maximizar el confort térmico, etc. En este esquema, la gestión en tiempo real del sistema HVAC tiene como objetivo minimizar el monto de la factura eléctrica mientras se maximiza el confort térmico, por lo que ambos costos deben integrarse en la función objetivo. El monto de la factura eléctrica (C_{EL}) depende del esquema tarifario de la distribuidora de energía (que es conocido) y de la demanda total de energía (P_t), que es variable. Por otro lado, el costo térmico es una función del PMV , como se observa en (2.13). La función costo puede escribirse como sigue:

$$j(P_t, PMV) = \sum_{j=0}^{N-1} \gamma^j [C_{El}(P_t(k+j)) + w \cdot C_{th}(PMV(k+j+1))] \quad (2.14)$$

donde N es el horizonte de predicción. γ es una tasa de descuento ($\gamma \leq 1$) incorporada para que los intervalos temporalmente cercanos sean más preponderantes que los lejanos, los cuales tienen mayores errores de predicción. Por lo tanto, su valor depende de la exactitud de los modelos de predicción siendo unitaria para modelos perfectos. Finalmente, w es un factor de compromiso entre confort y costo de electricidad. Su valor depende de cada caso ya que debe considerar las preferencias del usuario, pero también considerar que el costo de la electricidad normalmente es varios órdenes de magnitud superior al costo de confort. Puede obtenerse mediante simulación.

La demanda total en el instante k consta de la predicción de demanda de las cargas no controlables \hat{P}_{ND} (demanda base prevista, promediada durante el tiempo de medición del proveedor de energía, típicamente 15 minutos) y las cargas controlables (equipos HVAC).

$$P_t(k) = \hat{P}_{ND}(k) + \sum_{r=1}^m P_{hvac,r}(k) \quad (2.15)$$

B. Optimización

El problema de optimización se resuelve a partir de la minimización de la función costo descrita por (2.14), sujeta a restricciones de potencia y de PMV . De manera general, la formulación del problema de optimización puede describirse según (2.16), (2.17) y (2.18):

$$\min \sum_{j=0}^{N-1} \gamma^j [C_{El}(P_{hvac}(k+j)) + w \cdot C_{th}(PMV(k+j+1))] \quad (2.16)$$

suje to a (s.a)

$$\sum_{r=1}^m P_{hvac,r}(k+j) - P_{hvac,max}(k+j) \cdot e \leq 0 \quad (2.17)$$

$$|PMV_r(k+j+1)| - PMV_{max,r} \leq 0 \text{ for } r=1 \text{ to } m \quad (2.18)$$

con $0 \leq j \leq N-1$

La restricción eléctrica de (2.17) afecta directamente el funcionamiento de las unidades HVAC (variables manipulables) dado que $P_{hvac,max}$ es la potencia máxima disponible que el

sistema de climatización puede demandar y e es un coeficiente < 1 que disminuye dicha potencia disponible considerando el máximo error de predicción (depende de la exactitud de los predictores). De esta manera, se logra que la potencia no supere el límite impuesto. La restricción térmica de estado (2.18) limita la pérdida de confort en cada sala. Debido al uso del valor absoluto del PMV , la sensación de calor y frío en las salas se restringe de manera simétrica.

La optimización determina los valores de P_{hvac} obtenidos desde k hasta $k+N-1$, pero el controlador solo debe aplicar al sistema HVAC las señales correspondientes al primer intervalo de tiempo. Como resultado, la optimización desplaza temporalmente el funcionamiento de los equipos de climatización para evitar picos de demanda además de disminuir el consumo de energía conforme el valor numérico de w . La elección del horizonte de predicción debe ser tal que aproveche la capacidad de anticipación del MPC, pero también considere la dinámica del modelo térmico y los errores de predicción de las perturbaciones. Al resolver el problema de optimización a través de algoritmos heurísticos (optimización heurística), también se debe considerar el costo computacional: horizontes de predicción más largos implican espacios de búsqueda más extensos y, consecuentemente, un mayor costo computacional.

La gestión propuesta para sistemas de climatización requiere de conocer la demanda de las cargas no controlables (o demanda base), la tarifa eléctrica, la ocupación de las salas, la temperatura exterior y el modelo térmico. Excepto por el modelo RC y las tarifas, el resto de las variables se predicen para el horizonte temporal considerado.

2.3.5 Modelo de predicción de variables

La reconciliación de nivel se basa en la diferencia entre una medición actual real (en el intervalo k) y un valor esperado para el mismo instante. La predicción se realiza aplicando dicha diferencia al valor futuro esperado que desea estimarse.

Los modelos de predicción de temperatura exterior, ocupación de las salas (el calor emitido por personas se calcula a través de la ocupación y la tasa metabólica) y demanda base se llevan a cabo aplicando reconciliación de nivel con perfiles promedios [67]. En estos casos, las reconciliaciones de niveles se basan en la comparación de una medición actual (en el intervalo k) de la temperatura exterior, el calor generado por personas o la demanda base, con el valor de sus perfiles promedio diarios (\bar{T}_e , \bar{P}_{hr} y \bar{P}_{ND} , respectivamente) para el mismo momento del día. Esta diferencia se aplica a la componente del perfil promedio que desea estimarse. Los

perfiles promedio se generan a través de datos históricos; los mismos varían de mes a mes por su carácter estacional (temperatura exterior, concurrencia y consumo del centro).

Las expresiones matemáticas para llevar a cabo las predicciones de temperatura exterior \hat{T}_e , la demanda base(o demanda no despachable) \hat{P}_{ND} y calor emitido por personas \hat{P}_{h_r} en la sala r se describen en (2.19), respectivamente.

$$\begin{aligned}\hat{T}_e(k+j|k) &= (T_{out}(k) - \bar{T}_e(\text{mod}(k, N_e))) + \bar{T}_e(k + \text{mod}(j, N_e)) \\ \hat{P}_{ND}(k+j|k) &= (P_{ND}(k) - \bar{P}_{ND}(\text{mod}(k, N_e))) + \bar{P}_{ND}(k + \text{mod}(j, N_e)) \\ \hat{P}_{h_r}(k+j|k) &= (P_{h_r}(k) - \bar{P}_{h_r}(\text{mod}(k, N_e))) + \bar{P}_{h_r}(k + \text{mod}(j, N_e))\end{aligned}\quad (2.19)$$

donde mod es el operador residuo, siendo el primer argumento el dividendo y el segundo el divisor. N_e es el número de elementos de los perfiles promedio diarios (igual a 24 h/ t_s) y j indica el paso a predecir, a partir del instante actual k .

La predicción del calor humano producido en cada habitación (\hat{P}_{h_r}) puede ordenarse en un arreglo vectorial (\hat{P}_h) que contenga las predicciones de las m salas que constituyen un edificio:

$$\hat{P}_h(k+j|k) = [\hat{P}_{h_1}(k+j|k), \dots, \hat{P}_{h_m}(k+j|k)]' \quad (2.20)$$

Según (2.3) y (2.5) la predicción de perturbaciones puede calcularse teniendo en cuenta el pronóstico de la temperatura exterior, la predicción del calor generado por las personas y la predicción del calor emitido por las cargas (2.21). Si se considera al calor emitido por una carga como una proporción (δ) de la potencia demandada, se concluye que la perturbación predicha de la sala r (\hat{d}_r) es:

$$\hat{d}_r(k+j|k) = \frac{1}{C_r} \left(\hat{P}_{h_r}(k+j|k) + \frac{\hat{T}_e(k+j|k)}{R_r} + \delta \hat{P}_{ND} \right) \text{ con } 1 \leq r \leq m \quad (2.21)$$

Expresando las perturbaciones predichas de las m salas de un edificio en un arreglo vectorial, se obtiene:

$$\hat{d}(k+j|k) = [\hat{d}_1(k+j|k), \dots, \hat{d}_m(k+j|k)]' \quad (2.22)$$

2.4 Aplicación

Los centros de salud son de interés para la aplicación de estrategias de DR, ya que son los quintos mayores consumidores de energía eléctrica en el sector comercial, y el consumo de los sistemas HVAC es una parte representativa en su perfil de demanda [68]. Además, los equipos médicos con mayor consumo de energía funcionan a través de un sistema de turnos, lo que facilita la predicción de la demanda.

En esta sección, el esquema desarrollado se aplica a un CS que realiza tratamientos de radioterapia y diagnóstico por imágenes, ubicado en la provincia de Entre Ríos. Las unidades HVAC son las únicas cargas controlables; el resto de las cargas se consideran como demanda base (equipos médicos, iluminación, sistemas informáticos, etc.). El sistema de climatización del centro tiene un alto consumo de energía debido al gran tamaño que el centro tiene ($> 3000 \text{ m}^2$) y a los requisitos de confort de los pacientes, así como a las temperaturas necesarias para llevar a cabo algunos estudios médicos.

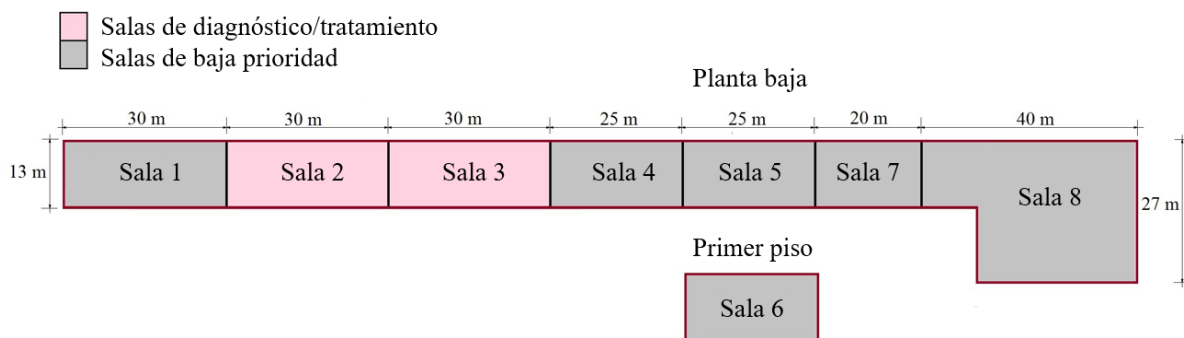


Figura 2.5. Plano del centro de salud.

Como se muestra en la Figura 2.5, el CS consta de 8 salas. Cada sala tiene 3 equipos de climatización gestionables, de 5.94 kW cada uno [42]. Los equipos de climatización son aires acondicionado ON/OFF tipo *split* para conductos de presión estática media. El compresor y el ventilador de los equipos funcionan en conjunto para satisfacer la carga de calefacción o refrigeración de la sala y se apagan simultáneamente una vez que se ha alcanzado la carga de calefacción o refrigeración. La distribución y el tamaño de los sistemas de conductos permiten velocidades del aire (v_a) en la sala de $\{0, 0.05, 0.1, 0.15\}$ m/s para $\{0, 1, 2, 3\}$ unidades encendidas por sala. Todas estas unidades HVAC tienen un CoP igual a 3 (valor estándar de equipos HVAC), lo que implica que, por cada kW de potencia eléctrica demandada, los equipos pueden aportar o absorber 3 kW de potencia térmica (según funcionen como calefacción o refrigeración).

La demanda de potencia del CS normalmente es inferior a 300 kW, pero ocasionalmente este límite es superado en verano, llegando a potencias cercanas a los 330 kW (Figura 2.6). La máxima demanda de potencia se produce durante el verano, en días calurosos, cuando funcionan los equipos de diagnóstico y tratamiento en simultaneo con la elevada demanda de los equipos de climatización.

Para realizar este estudio se utilizó información de potencia activa trifásica disponible en el *datalogger* del CS. El registro contenía valores de demanda total del año 2018, con intervalos de medición de 15 minutos. Esta información se resume en las Figura 2.6 y Figura 2.7.




Figura 2.6. Diagrama de cajas de la demanda de potencia de cada mes.

La Figura 2.6 muestra la distribución de la demanda para cada mes y la Figura 2.7 muestra el perfil promedio de demanda diaria mensual. Cada perfil promedio se obtuvo promediando los perfiles diarios durante un mes.




Figura 2.7. Demanda de potencia promedio de cada mes.

El esquema tarifario del distribuidor de energía provincial considera aumentos del 40% en la tarifa de energía (\$/kWh) para usuarios con demandas que superan los 300 kW; una vez que se supera esta demanda, la tarifa de energía con penalidad se aplica durante los siguientes cuatro meses. Por esta razón, la demanda del CS debe ser inferior a 300 kW.

2.4.1 Esquema tarifario aplicado al Centro de Salud

La Tabla 2.2 muestra la tarifa TOU de ENERSA, la distribuidora de energía provincial, para grandes usuarios (T3), como el CS. Se aplican dos tarifas de potencia por hora (pico y fuera de pico) y tres de energía (pico, valle y restante).

Costo		Unidad	< 300 kW	≥ 300 kW
Fijo		\$/mes	12855.91	12855.91
Por potencia	Pico (18h-23h)	\$/kW-mes	990.98	990.98
	Fuera de pico (23h-18h)	\$/kW-mes	844.17	844.17
	Adquirida	\$/kW-mes	78.26	78.26
Por energía	Pico (18h-23h)	\$/kWh	10.1102	14.2241
	Valle (23h-5h)	\$/kWh	9.8198	14.2076
	Restante (5h-18h)	\$/kWh	9.9644	14.2165

Tabla 2.2. Tarifas aplicadas al centro de salud (enero de 2023 para usuarios de baja tensión [69]).

En la Tabla 2.2 se observa que la tarifa de potencia es independiente de la potencia demandada, pero la tarifa de energía aumenta alrededor del 40% cuando la demanda es mayor a 300 kW.

La facturación mensual de electricidad (C_{TE}) se calcula mediante la suma de tres costos: el costo fijo (C_F), el costo de demanda (C_P) y el costo de consumo (C_E) [70], de acuerdo a:

$$C_{TE}=C_F+C_P+C_E \quad (2.23)$$

Como se mencionó anteriormente, la demanda rara vez supera los 300 kW, pero el máximo detectado se acerca a los 330 kW. Cuando estos picos de demanda no se gestionan, la tarifa de energía aplicada al CS durante los próximos cuatro meses es la más costosa. La medición de potencia demandada a la red se realiza efectuando el promedio de la demanda durante 15 minutos continuos.

Por otro lado, la Ley Nacional N° 27191 establece que los usuarios con demandas mayores a 300 kW deben cumplir con el porcentaje de consumo de energía renovable (20% del consumo total, para el año 2025), a través de autogeneración o de contratos de compra de energía renovable [71]. Incorporar este costo adicional implica aumentar notablemente el costo del kWh consumido para estos usuarios, por lo que superar este umbral es un gran riesgo para ellos. En consecuencia, la utilización de estrategias de gestión de energía que eviten superar la demanda de potencia permitida, permite obtener grandes ahorros para estos usuarios.

2.4.2 Formulación del controlador predictivo del Centro de Salud

El MPC enciende/apaga las unidades HVAC para reducir el costo eléctrico y maximizar el confort, teniendo en cuenta restricciones térmicas y de demanda. La restricción de demanda implica que la potencia promedio durante cada intervalo no puede superar los 300 kW, y la restricción de confort establece los límites superiores e inferiores de la potencia del sistema HVAC que permite una temperatura interior satisfactoria para los ocupantes. Además, el controlador utiliza la predicción de la temperatura exterior, la demanda base y la ocupación de personas para un horizonte dado ($k, k+N-1$), donde k es el primer intervalo predicho y N es el horizonte de predicción considerado. Luego, resuelve la optimización propuesta para ese horizonte y actúa solo sobre la potencia de las unidades HVAC (a través del número de unidades encendidas por sala) en el intervalo actual, utilizando los estados resultantes de la optimización.

A. Modelo térmico de Centro de Salud

El modelo térmico del CS se obtiene extendiendo el circuito equivalente (Figura 2.2) para todas las salas del edificio (Figura 2.5), usando la representación de espacio de estados continua de (2.6). La matriz A es:

$$A = \begin{bmatrix} \alpha_1 & \frac{1}{C_1 R_{12}} & 0 & 0 & 0 & 0 & 0 & 0 \\ \frac{1}{C_2 R_{12}} & \alpha_2 & \frac{1}{C_2 R_{23}} & 0 & 0 & 0 & 0 & 0 \\ 0 & \frac{1}{C_3 R_{23}} & \alpha_3 & \frac{1}{C_3 R_{34}} & 0 & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{C_4 R_{34}} & \alpha_4 & \frac{1}{C_4 R_{45}} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{C_5 R_{45}} & \alpha_5 & \frac{1}{C_5 R_{56}} & \frac{1}{C_5 R_{57}} & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{C_6 R_{56}} & \alpha_6 & 0 & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{C_7 R_{57}} & 0 & \alpha_7 & \frac{1}{C_7 R_{78}} \\ 0 & 0 & 0 & 0 & 0 & 0 & \frac{1}{C_7 R_{78}} & \alpha_8 \end{bmatrix}$$

D es una matriz identidad de 8x8 y B es una matriz diagonal que incluye CoP de las unidades HVAC, siendo todos iguales a $\eta=3$. El valor del CoP se obtiene dividiendo la capacidad de refrigeración sobre la demanda eléctrica. Los signos negativos en los elementos de B indican operación de refrigeración.

$$B=\text{diag}\left(\frac{-3}{C_1}, \frac{-3}{C_2}, \frac{-3}{C_3}, \frac{-3}{C_4}, \frac{-3}{C_5}, \frac{-3}{C_6}, \frac{-3}{C_7}, \frac{-3}{C_8}\right)$$

Muestreando las matrices continuas con un tiempo de muestreo t_s , se obtiene la representación discreta de espacio de estados de (2.7) [42]. Los parámetros R y C se calculan mediante tablas que consideran el tamaño de cada sala y los objetos dentro de ellas; los materiales de las paredes/pisos/techos además del grosor de cada capa constitutiva; y el número y tamaño de puertas/ventanas [72]. La Tabla 2.3 expone los parámetros térmicos R y C de cada sala, además de mostrar las dimensiones utilizadas para su determinación. WSA es el área superficial de paredes que incluye el área de las paredes interiores no compartidas, pisos y techos. El volumen se calcula con las dimensiones interiores de cada sala.

Teniendo en cuenta características constructivas y dimensiones del CS, se estiman las resistencias de las paredes compartidas ($R_{12}, R_{23}, R_{34}, R_{45}, R_{56}, R_{57}$ y R_{78}) iguales a $8.24 \text{ }^\circ\text{C/kW}$ en todos los casos. La resistencia térmica de las paredes exteriores se calcula mediante la transmitancia térmica, considerada igual a $1.022 \text{ W/m}^2 \text{ }^\circ\text{C}$, Este modelo se verificó mediante la comparación de un perfil de demanda real con uno simulado, considerando igual demanda base y temperatura exterior.

Sala	WSA (m ²)	Volumen (m ³)	R (°C/kW)	C (kWh/°C)	Número de equipos AC	Potencia cada equipo (kW)	$ PMV_{max} $
1	219	1170	0.45	2.96	3	5.94	1
2	180	1170	0.55	2.96	3	5.94	0,75
3	180	1170	0.55	2.96	3	5.94	0,75
4	150	975	0.67	2.44	3	5.94	1
5	150	975	0.67	2.44	3	5.94	1
6	204	1170	0.46	2.96	3	5.94	1
7	120	780	0.83	2	3	5.94	1
8	291	1140	0.34	3.62	3	5.94	1

Tabla 2.3. Parámetros térmicos de las salas del centro de salud.

La Tabla 2.3 muestra también la configuración del sistema HVAC y las restricciones de PMV de cada sala. Se establece un esquema de prioridad de confort según la importancia de cada sala descrita en la Figura 2.5. A las salas de mayor importancia, como las de

diagnóstico/tratamiento, se les asigna la restricción $-0.75 \leq PMV \leq 0.75$ y a las de menor importancia, la restricción $-1 \leq PMV \leq 1$.

B. Modelos de predicción de variables

Los modelos de predicción se desarrollan utilizando las ecuaciones de (2.19). Los perfiles promedio se generan mediante datos históricos (enero de 2018) y considerando intervalos de medición de 15 minutos. La Figura 2.8 muestra los perfiles promedio de temperatura exterior (\bar{T}_e), demanda no despachable (\bar{P}_{ND}) y potencia térmica emitida por las personas en la sala 5 (\bar{P}_{h5}). \bar{P}_{h5} se obtiene multiplicando el perfil promedio de ocupación de la sala 5 por la potencia emitida por persona (120 W para personas sentadas o realizando trabajo liviano [73], [74]).

El horario de funcionamiento del CS es de 6:00 a 00:00 horas, por lo que durante este período hay personas dentro emitiendo potencia térmica. Por el contrario, de 00:00 a 6:00 horas el CS se encuentra cerrado por lo que se supone que la potencia térmica emitida por humanos es nula. Esto se muestra en la Figura 2.8 (gráfica de abajo).

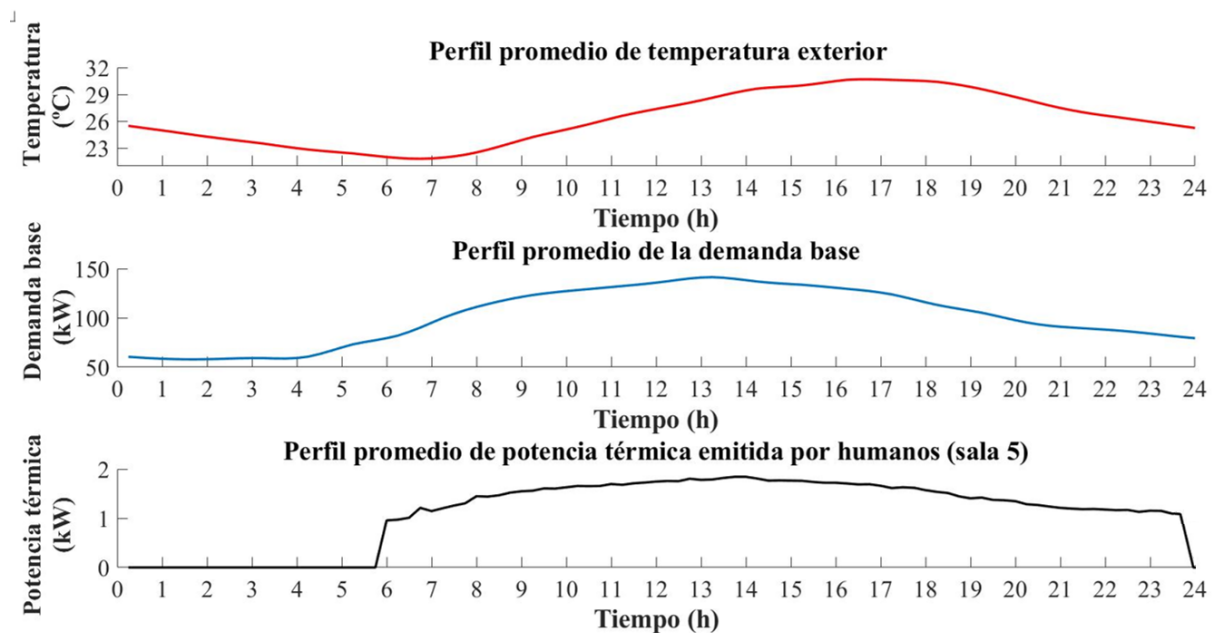


Figura 2.8. Perfiles promedio de temperatura exterior (arriba), demanda base (medio) y potencia térmica emitida por humanos en la sala 5 (abajo).

La predicción de las perturbaciones se realiza con el pronóstico de la temperatura exterior y el IHG (potencia térmica emitida por las personas, las luces y el equipamiento electro-médico), según (2.21).

C. Función costo

El costo de electricidad debe tener en cuenta la demanda total de potencia P_l (2.15), además de la tarifa horaria de energía y de potencia de la distribuidora (Tabla 2.2), T_E y T_P , respectivamente.

$$C_{El}(P_{hvac}(k))=(T_P(k)+t_s \cdot T_E(k)) \left(\hat{P}_{ND}(k)+\sum_{r=1}^m P_{hvac,r}(k) \right) \quad (2.24)$$

El producto de t_s , T_E y P_l determina el costo de energía del intervalo k ; y el producto de T_P y P_l determina el costo de potencia en el mismo intervalo. Dado que los equipos de climatización del CS tienen tecnología tradicional (no son *inverter*), P_{hvac} depende del número de unidades encendidas (v es el vector que contiene el número de unidades HVAC encendidas en cada sala) y la potencia nominal por unidad (p_{hvac}), es decir:

$$P_{hvac}(k)=v(k) \cdot p_{hvac} \quad (2.25)$$

La ecuación (2.13) puede ser utilizada como costo térmico, parametrizando el caso de aplicación de la siguiente manera: $M=60 \text{ W/m}^2$ (considerando personas sentadas o en reposo), $W=0 \text{ W/m}^2$ e $I_{cl}=0.2 \text{ m}^2\text{K/W}$ (para ropa de verano) [73]. Por lo tanto, la función de costo del CS (J_{CS}) es:

$$J_{CS}(v,PMV)=\sum_{j=0}^{N-1} \gamma^j [(T_P(k+j)+t_s \cdot T_E(k+j)) \left(\hat{P}_{ND}(k+j)+p_{hvac} \sum_{r=1}^m v_r(k+j) \right) +w \sum_{r=1}^m c_r |PMV_r(k+j+1)|] \quad (2.26)$$

D. Optimización

Las prioridades de confort de cada sala se establecen, en este caso de estudio, únicamente en las restricciones y no en la función costo, por lo que el vector c de (2.13) es unitario. El valor de la tasa de descuento γ es 0.95. Este valor asegura que los términos futuros de (2.27) sean considerados, pero que cada vez sean menos preponderantes en la función costo a medida que se alejan temporalmente del instante actual. De esta manera, se mitigan los errores adicionados por los modelos de predicción. Por otro lado, para seleccionar el valor de w en (2.14) se contempló la diferencia de órdenes de magnitud entre el costo de la electricidad y el costo de confort. Se utilizó $w = 80000$, valor determinado a través de simulación. Los valores finales de w y γ mencionados se ajustaron por simulación.

La formulación del problema de optimización es la siguiente:

$$\min J_{CS}(v, PMV) \quad (2.27)$$

s.a

$$Co_1(k) = p_{hvac} \sum_{r=1}^m v_r(k+j) - P_{av}(k+j) \cdot e \leq 0 \quad (2.28)$$

$$Co_2(k) = |PMV_r(k+j+1)| - PMV_{\max, r} \leq 0 \text{ for } r=1 \text{ to } 8 \quad (2.29)$$

$$\text{con } 0 \leq j \leq N-1$$

La restricción (2.28) evita que la demanda del sistema HVAC supere la potencia disponible P_{av} , calculada como la diferencia entre el límite de 300 kW y la demanda base. La ecuación (2.29) es una restricción de confort térmico que establece las prioridades de cada sala. En este caso de estudio, se implementa un esquema de prioridad de dos niveles: salas de alta prioridad ($|PMV| \leq 0.75$) y salas de baja prioridad ($|PMV| \leq 1$) (ver Tabla 2.3).

2.5 Simulaciones

La estrategia desarrollada se compara con otra no optimizada, con y sin recorte de pico, que determina el número de unidades de climatización encendidas en función de bandas de temperatura predefinidas. La estrategia no optimizada sin RP enciende una unidad HVAC si la temperatura ambiente está por debajo de 22.75 °C, dos unidades si está por debajo de 24.625 °C y tres unidades si está por encima de 24.625 °C. Si la temperatura es inferior a 20.875 °C, la estrategia apaga todas las unidades HVAC. Este control emula el funcionamiento de equipos HVAC con tecnología *inverter*, en bloques de equipos tradicionales (*no-inverters*) que funcionan en conjunto. Los valores límites de temperatura de la banda se estiman para coincidir, de manera aproximada, con $-1 \leq PMV \leq 1$. Con RP, la estrategia controla eficientemente los equipos, apagando las unidades HVAC en las salas con la temperatura más baja para mantener la demanda por debajo de 300 kW mientras se mantiene el confort.

Las estrategias se comparan en un día de verano con elevada temperatura exterior alta y demanda base. Para la estrategia basada en MPC, se utilizan diferentes horizontes de predicción para evaluar la mejor opción. Además, se evalúa la disminución en el rendimiento de la estrategia debido a los errores introducidos por los modelos de predicción.

Dado que el escenario diario propuesto rara vez ocurre (por lo general, la demanda del CS es < 300 kW), para obtener el costo mensual de electricidad, se asume que solo 5 días de enero tienen condiciones similares a este escenario y los 26 días restantes la potencia total del CS es

igual a la demanda promedio actual [42]. Por otro lado, y para simplificar, el costo térmico se calcula solo para el día simulado (diariamente).

2.5.1 Simulaciones y parámetros del algoritmo genético

El tiempo de muestreo t_s se considera igual al tiempo de medición utilizado por la distribuidora de energía, es decir, 0.25 horas (15 minutos). El tiempo de simulación se configuró para un día; por lo tanto, el número de intervalos en un día es $n = \frac{24 \text{ h}}{t_s} = 96$ intervalos. Las estrategias de gestión de unidades HVAC se aplican cuando el CS está abierto (de 6:00 h a 00:00 h), por lo que el número de ventanas de optimización por día es de 72. Las simulaciones se realizan con los siguientes horizontes de predicción: {1, 2, 3} horas, equivalentes a {4, 8, 12} intervalos. Luego, las variables de optimización se calculan como el producto del número de salas, la cantidad de intervalos por hora ($1/t_s = 4$) y el horizonte de predicción N (expresado en horas). Es decir, $8 \cdot 4 \cdot N$ (en horas) lo que resulta en {32, 64, 96} variables para N {1, 2, 3} horas, respectivamente. Teniendo en cuenta que cada variable puede tomar cuatro valores, que indica el número de unidades HVAC encendidas por sala, el número de combinaciones posibles para cada N es { 4^{32} , 4^{64} , 4^{96} }.

Dado que el problema de optimización se resuelve con un algoritmo genético, es importante elegir las semillas adecuadas para cada momento con el fin de obtener buenas soluciones. Cada ventana de optimización del MPC determina los estados óptimos de los equipos HVAC (encendidos/apagados) desde el tiempo k hasta el tiempo $k+N-1$. Por lo tanto, en la siguiente ventana de optimización, este vector de estados puede ser utilizado como una semilla considerando un desplazamiento temporal unitario. Este proceso iterativo permite que cada optimización encuentre mejores semillas. Además, los estados de las unidades de climatización obtenidos con la estrategia de control de banda de temperatura también se utilizan como semillas. Los parámetros del algoritmo genético utilizado para resolver la optimización, son: 600 iteraciones, 100 individuos por iteración, tasa de cruce del 0.82 y selección de los 5 mejores individuos en cada ronda.

2.5.2 Resultados

En la Tabla 2.4 se cuantifica el rendimiento de las estrategias basada en MPC y en control por banda de temperatura (estrategia optimizada y estrategia no optimizada, respectivamente). Las simulaciones de la estrategia optimizada se realizan utilizando modelos de predicción y

diferentes horizontes (N). Las simulaciones de la estrategia no optimizada se llevan a cabo con y sin RP. La Tabla 2.4 sugiere que el costo mensual total de electricidad (C_{TE}) obtenido al implementar la estrategia optimizada y la estrategia no optimizada con RP es prácticamente el mismo porque en ambos casos la potencia máxima es inferior a 300 kW, obteniendo el costo más bajo para $N = 12$ intervalos.

Estrategia	MPC			Por banda de temperatura	
				Con RP	Sin RP
N	4	8	12	-	-
C_{TE} (\$)	1653800	1654464	1644893	1649428	2153189
C_{TH}	96.9	112.9	128.1	183.5	145.7
Pico de potencia (kW)	299.7	299.7	299.7	299.3	324.4
Tiempo de optimización (s)	13.92	20.9	25.0	-	-

Tabla 2.4. Comparación de las estrategias.

Por otro lado, el costo eléctrico aumenta notablemente en la simulación de la estrategia no optimizada sin RP (un aumento del 30% sobre las otras simulaciones) debido a que la potencia máxima es de 324.4 kW, superando el umbral de 300 kW y, por lo tanto, se aplica al CS la tarifa de energía más costosa durante el mes en curso.

Al comparar el confort de ambas estrategias, la estrategia optimizada logra un costo térmico diario (C_{TH}) más bajo que las estrategias por bandas de temperatura, para todos los horizontes de predicción. El mejor confort se logra con $N = 4$. En este caso, se obtiene una mejora de más del 47% en comparación con la estrategia con RP, e incluso más del 33% en comparación con la estrategia sin RP.

Dado que el coeficiente w es igual a 80000, el costo de confort tiene una mayor relevancia que el costo eléctrico en la función de costo (2.26), porque se prioriza el confort de los pacientes.

El tiempo de optimización es el tiempo empleado para resolver el problema de optimización de cada ventana temporal. El mismo crece proporcionalmente con N , ya que aumenta el número de variables a optimizar. Estos tiempos son aceptables en comparación con la duración del intervalo (15 minutos) y la simulación puede realizarse 20 segundos antes del intervalo de control. Los tiempos de optimización se obtuvieron con una computadora integrada por un procesador Ryzen 7 4800H, una tarjeta de video GeForce GTX 1650 y 8 GB de memoria RAM (DDR4). Se utilizaron los mismos parámetros de AG para todas las simulaciones de la estrategia basada en MPC. Sin embargo, se recomienda aumentar el número de iteraciones, la población inicial y los mejores individuos del AG para espacios de búsqueda más grandes, con el fin de obtener mejores soluciones. En consecuencia, se necesitarían tiempos de optimización más

largos para horizontes de 8 y 12 intervalos. Teniendo en cuenta el tiempo de optimización y los resultados obtenidos en las simulaciones, $N = 4$ es la mejor opción para este caso de estudio.

La Tabla 2.5 muestra el rendimiento de la estrategia optimizada utilizando predicción perfecta. En este caso, los modelos de predicción son ideales (no tienen error) por lo que los valores de las variables predichas son iguales a los reales. Esto permite evaluar cómo los errores de los modelos de predicción afectan el desempeño de la estrategia.

El costo térmico mínimo, para el escenario diario propuesto y la estrategia desarrollada, se obtiene para $N = 4$ y $N = 8$, y es cercano a 90.

N	4	8	12
C_{TE} (\$)	1647388	1647639	1644334
C_{TH}	89.9	90.2	93.3
Pico de potencia (kW)	299.9	299.9	299.8
Tiempo de optimización (s)	13.4	20.2	24.9

Tabla 2.5. Desempeño de la estrategia optimizada para diferentes horizontes con predicción perfecta.

Una comparación entre las Tabla 2.4 y Tabla 2.5 sugiere que los modelos de predicción introducen errores que afectan el rendimiento de la estrategia, ya que con una predicción perfecta los costos disminuyen. En cuanto al confort, al comparar entre los mismos horizontes, para $N = 4$, la disminución en el rendimiento de la estrategia es del 8%, mientras que para $N = 8$ es del 25% y para $N = 12$ es del 37%. Dado que la optimización debe lograr un equilibrio entre costo y confort, la disminución en el costo se debe a la pérdida de confort (menor consumo de los equipos HVAC). Por esta razón, la estrategia con un horizonte de 12 intervalos tiene los peores costos de confort. En general, al utilizar predicción perfecta se obtienen mejores resultados en comparación con la utilización de modelos de predicción. Sin embargo, este no es un caso real ya que representa un modelo de predicción ideal.

La Figura 2.9 representa los diagramas de cajas del PMV para salas de alta y baja prioridad. La estrategia basada en MPC muestra una baja dispersión de los valores de PMV en ambos tipos de salas, estando sus medianas más cerca de cero en comparación con las estrategias de bandas de temperatura. Para la estrategia optimizada con $N = 4$, los valores de PMV , además de estar comprimidos, son simétricos con respecto a cero. La estrategia no optimizada con RP tiene la mayor dispersión y asimetría, lo que explica su mayor costo de confort (Tabla 2.4).




Figura 2.9. Diagrama de cajas del PMV para la estrategia MPC usando modelos de predicción y la estrategia de bandas de temperatura para a) salas de baja prioridad, b) salas de alta prioridad.

Además, esta estrategia no mantiene el confort en los valores requeridos para las salas de alta prioridad. En la estrategia sin RP, los valores de PMV obtenidos están más comprimidos, pero aún son asimétricos con respecto a cero.

Las Figura 2.10 - Figura 2.13 muestran una comparación entre las estrategias MPC con $N = 4$, utilizando predicción de variables y la estrategia de control por banda de temperatura con RP. La Figura 2.10 muestra los perfiles de temperatura de todas las salas. En el escenario con MPC, la temperatura de las salas oscila entre los límites impuestos por las restricciones de PMV , mientras que, en la estrategia no optimizada, la temperatura de la sala 1 supera el límite superior en dos ocasiones. Además, es visible la menor dispersión de temperatura que se observa en términos del PMV , como se muestra en la Figura 2.9. Lo mismo se observa en las Figura 2.11 y Figura 2.12, que muestran el confort. Además, la Figura 2.12 ilustra que el MPC logra un mejor confort en las salas de alta prioridad en comparación con la estrategia no optimizada. La Figura 2.13 muestra la demanda de energía diaria para las dos estrategias. El pico de potencia a las 6:00 AM en ambas estrategias se debe a que el CS comienza a funcionar, requiriendo mucha energía para refrigerar debido a las altas temperaturas exteriores y de las salas.

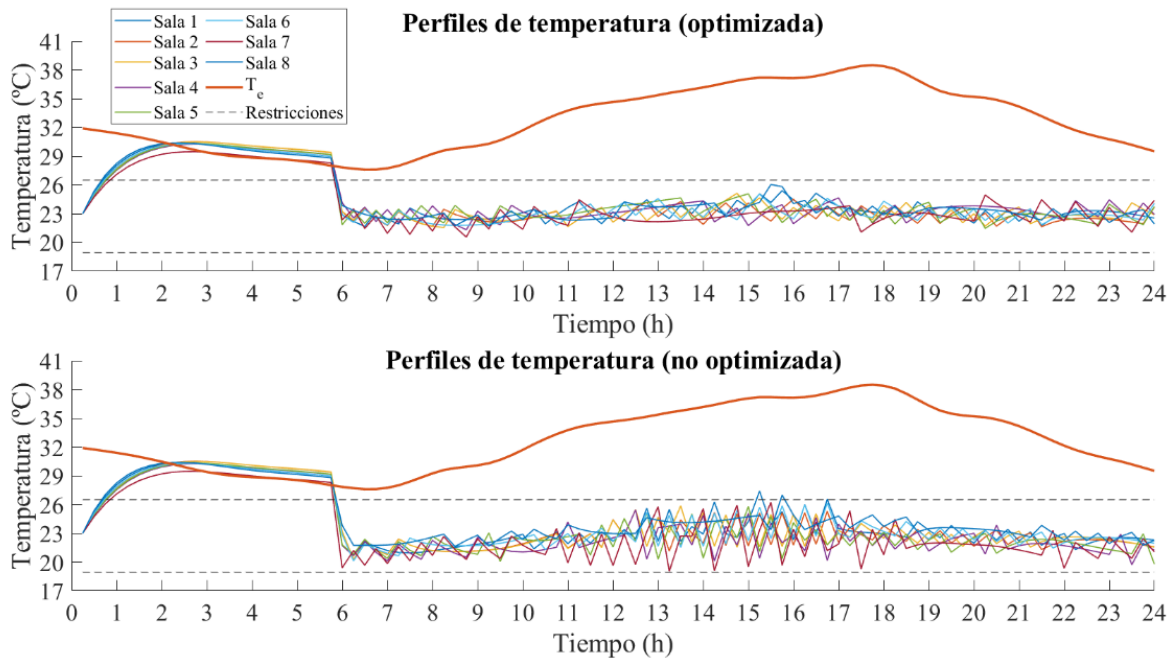


Figura 2.10. Perfiles de temperatura interiores diarias para a) MPC con $N = 4$ y b) control por banda de temperatura con RP.

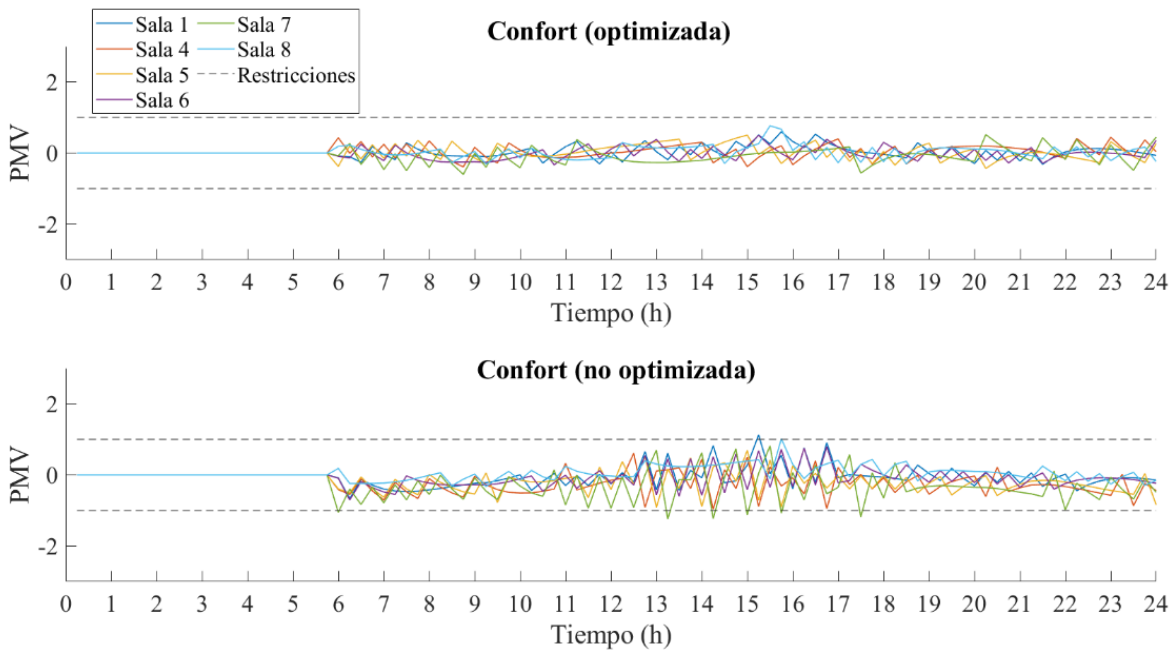


Figura 2.11. Evolución diaria del PMV de las salas de baja prioridad para a) MPC con $N = 4$ y b) control por banda de temperatura con RP.

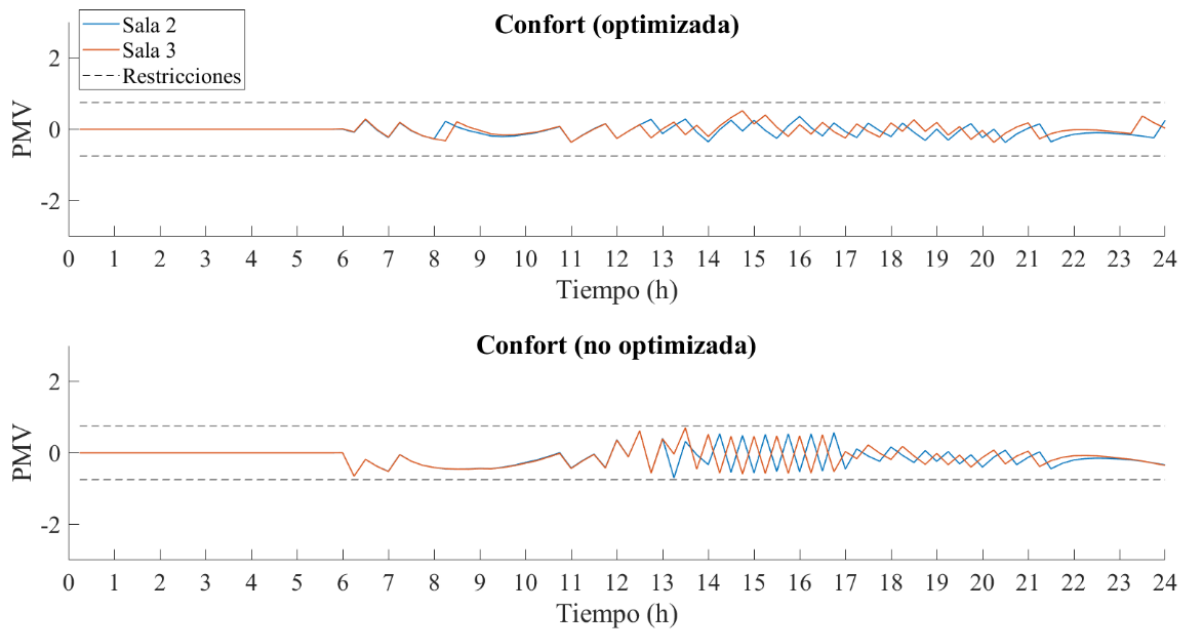


Figura 2.12. Evolución diaria del PMV para las salas de alta prioridad para a) MPC con $N = 4$ y b) control por banda de temperatura con RP.

Los perfiles de potencia son similares y en ningún caso se supera el límite de 300 kW, lo que explica que el costo eléctrico también sea similar, como indica la Tabla 2.4. Sin embargo, el MPC logra un mejor confort que la estrategia no optimizada.

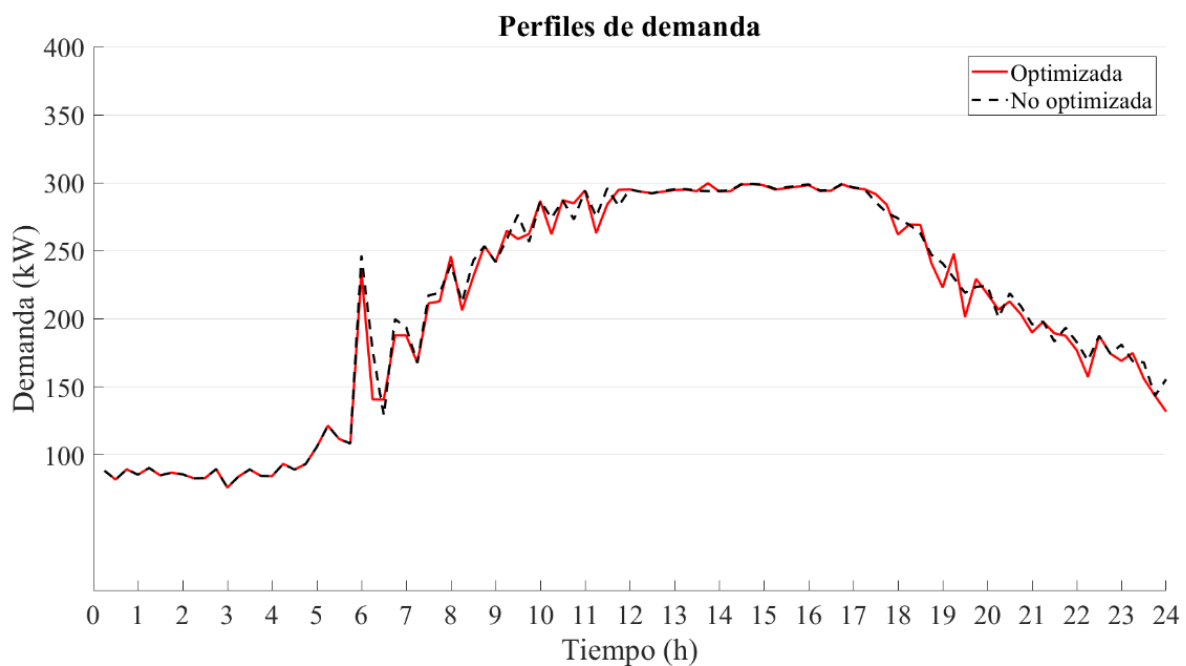


Figura 2.13. Demanda de potencia diaria utilizando la estrategia MPC con $N = 4$ y el control por banda de temperatura con RP.

Para un día con el mismo perfil de temperatura exterior y ocupación, pero con una demanda base baja (de manera que el control por banda de temperatura no requiera RP), la estrategia basada en MPC, utilizando la predicción de variables y $N = 4$, obtiene un costo térmico de 89.6, mientras que la estrategia por banda de temperatura obtiene 145.7. Por lo tanto, la estrategia optimizada mejora el confort térmico en un 38%. El costo eléctrico mensual obtenido con ambas estrategias es aproximadamente el mismo: \$1530662 para la optimizada y \$1533844 para la no optimizada. Por lo tanto, la estrategia basada en MPC muestra su utilidad en ambos escenarios (con demanda base baja y elevada), mejorando el confort de los pacientes y los trabajadores del CS y logrando un bajo costo en la factura eléctrica.

2.6 Discusión

En este capítulo, se desarrolló un esquema basado en MPC para la gestión de equipos HVAC en tiempo real que puede implementarse en soluciones de bajo costo. La estrategia se aplicó al caso de estudio de un centro de salud y se comparó con una estrategia de control por banda de temperatura con y sin recorte de picos.

La gestión óptima propuesta logra un mayor confort y un costo eléctrico similar al de la estrategia de banda de temperatura con recorte de picos, para todos los horizontes de predicción. Al utilizar predicción perfecta en la estrategia MPC, se obtienen los mejores resultados para cualquier horizonte de predicción, pero no es físicamente aplicable porque representa el caso de un predictor ideal. Sin embargo, al incluir modelos de predicción reales, se obtienen costos eléctricos similares y con pérdidas de confort aceptable respecto al caso de predicción perfecta, particularmente para un horizonte de 1 hora ($N=4$). Este horizonte fue el seleccionado debido al gran rendimiento en comparación con la estrategia de banda de temperatura con recorte de picos (mejora del confort cercana al 47%, manteniendo el costo eléctrico) y su bajo costo computacional (tiempo de optimización de 13 s). En comparación con la misma estrategia sin recorte de picos, la gestión propuesta muestra una mejora en el confort y una disminución del costo eléctrico (33% y 23%, respectivamente).

Capítulo 3

GESTIÓN PREDICTIVA DEL DESPACHO DE GENERACIÓN Y DE LA DEMANDA APLICABLE A MICRORREDES QUE INCLUYEN SISTEMAS DE CLIMATIZACIÓN

3.1 Resumen del capítulo

En este capítulo, se propone un esquema de control predictivo basado en modelo para gestionar de manera conjunta la demanda y el despacho de generadores en microrredes que incluyen sistemas de climatización. Los generadores de energía, los dispositivos de almacenamiento y las cargas controlables se gestionan simultáneamente para optimizar el uso energético en la microrred sin perder el confort térmico. Se aplican estrategias de gestión de la demanda de manera explícita (directamente en cargas controlables) e implícita (optimizando la operación del sistema utilizando la inercia térmica). El esquema MPC se basa en modelos lineales de parámetro variable (LPV, *linear parameter varying*) del sistema HVAC y del banco de baterías, además de modelos de predicción de temperatura exterior, generación renovable y cargas no controlables. Dado que el MPC tolera gran diferencia entre planta y modelo, los modelos de pronóstico simples son adecuados para las predicciones requeridas. Las señales de programación del modelo LPV se predicen para estimar los parámetros variables en el tiempo de manera de mejorar el control retroalimentado y de avance. Se derivan formulaciones de MPC implementables en sistemas embebidos para gestionar microrredes que operan con y sin conexión. El esquema desarrollado se aplica a dos casos de estudio de interés regional, una granja avícola automatizada (aislada de la red) y el centro de salud (conectado a la red) descrito en el Capítulo 2. La granja integra paneles fotovoltaicos, baterías, generador diésel, cargas no controlables y equipos de climatización. El centro de salud integra baterías, paneles fotovoltaicos, cargas no controlables y un sistema de climatización. Los resultados de las simulaciones demuestran la efectividad y los beneficios económicos que se obtienen al utilizar las estrategias propuestas. Para el caso aislado, la estrategia proporcionó un ahorro de combustible del 55% y un mejor uso de los recursos en comparación con un controlador convencional basado en reglas. Por otro lado, para el caso conectado, la estrategia proporcionó un ahorro mensual en la factura del 26% y un ahorro de inversión del 750%, al compararlo con la instalación de energía fotovoltaica requerida para cumplir las obligaciones de usuarios con demandas mayores a 300 kW.

3.2 Introducción

En el nuevo paradigma de las REI, implementado mediante GD y GR, las MRs desempeñan un papel fundamental. Contribuyen a mejorar el funcionamiento y la confiabilidad de las redes de distribución mediante la reducción de pérdidas de transmisión y de los tiempos de interrupción. Además, optimizan la integración de recursos de energía distribuidos y representan una solución para aquellos usuarios que no tienen acceso a la red de distribución [75], [76], [77]. Las MRs están especialmente diseñadas para tener una alta penetración de energías renovables (por ejemplo, eólica, fotovoltaica, hidrocínética, biomasa, etc.) [3], por lo que su desarrollo implica una serie de desafíos operativos asociados a la intermitencia de los recursos y la consecuente incertidumbre en la generación [78].

Los sistemas HVAC tienen un alto consumo de energía y en consecuencia una gestión inteligente de estos sistemas puede proporcionar una reducción significativa de costos y mejorar la eficiencia de los sistemas de potencia. La DSM y la DR son enfoques aplicados al lado de la carga, que permiten obtener beneficios técnicos y económicos mediante el ajuste del consumo de electricidad para equilibrar generación y demanda [20]. Por lo tanto, estos enfoques son particularmente útiles cuando la penetración de energía renovable es alta, ya que la generación puede fluctuar debido a la variabilidad de los recursos [79]. Habilitada por la infraestructura avanzada de medición y otras tecnologías de redes inteligentes, se espera que estas estrategias sean un mecanismo crucial para compensar las incertidumbres del sistema y otros riesgos asociados, incluidos los relacionados con la generación renovable intermitente [80]. En este capítulo, se discuten los desafíos relacionados con la predicción de carga y la gestión de la demanda.

La mayoría de los trabajos publicados proponen la gestión del despacho de generación y de la demanda de manera independiente en MRs, con métodos diversos. El control por banda de histéresis es ampliamente utilizado para gestionar dispositivos de almacenamiento [81]. Algunos trabajos proponen el control por banda del estado de la carga de baterías (*state of charge*, SoC) y de celdas de combustible en MRs aisladas de la red que incluyen paneles fotovoltaicos y aerogeneradores [82], [83]. En general, su implementación es sencilla pero no incluye criterios económicos y no brinda resultados óptimos. Una nueva tendencia utiliza algoritmos de aprendizaje por refuerzo [84] y aprendizaje por refuerzo profundo [85] para gestionar dispositivos de almacenamiento en MRs conectadas a red con generación renovable híbrida. Algoritmos de aprendizaje por refuerzo también han sido utilizados para el desarrollo de estrategias de DR aplicados a sistemas HVAC, donde en general se busca maximizar el

confort térmico, minimizar el consumo de energía y, en menor medida, controlar los niveles de emisión de CO₂ en edificios [86].

Los esquemas MPC tienen ventajas sobre otros métodos de control para gestionar la generación/almacenamiento de energía y la demanda en MRs [87]. Esto se debe a que el MPC puede manejar incertidumbres/perturbaciones, además de considerar restricciones físicas/operativas en el problema de optimización y utilizar predicciones de generación/demanda. Por otro lado, estos controladores se basan principalmente en el comportamiento futuro del sistema, lo cual es un aspecto muy importante en sistemas que incorporan generación renovable [8]. Además, el MPC permite abordar el problema de optimización definiendo una función multiobjetivo para tener en cuenta simultáneamente objetivos económicos, de confort y de control. Por esta razón, varios trabajos recientes han propuesto la gestión de despacho en MRs utilizando MPC. Por ejemplo, en [88] se propuso un despacho económico basado en un esquema de tarifas dinámicas para una MR aislada de la red con una turbina eólica, o en [89], donde se utilizó un MPC para controlar las baterías, el generador diésel y el *setpoint* de potencia de los paneles fotovoltaicos.

Por otro lado, la utilización de MPC en la gestión de equipos de climatización ha tenido gran interés en los últimos años, principalmente debido al aumento en la capacidad computacional de los sistemas de automatización [45]. El MPC permite desarrollar programas de respuesta a la demanda aplicados a equipos HVAC utilizando modelos térmicos, predicciones de temperatura exterior e inclusión de restricciones de demanda [54]. En este sentido, un trabajo reciente propuso un controlador MPC para implementar estrategias de recorte de pico y desplazamiento de carga en la gestión de energía térmica en edificios y residencias [46].

La gestión conjunta de la generación y la demanda puede proporcionar una mejora significativa en la eficiencia de los sistemas eléctricos. Siguiendo esta línea, los autores de [90] presentan un modelo de gestión de la demanda de cargas inteligentes con gestión de despacho de energía y de demanda máxima en una MR aislada. Un controlador predictivo determina los puntos de consigna de los generadores y las baterías además de la potencia disponible que puede suministrarse a las cargas inteligentes, considerada como una señal de respuesta a la demanda. En este caso, no se desarrolló una estrategia de DSM, ya que las cargas inteligentes determinan su consumo. Otro artículo propone un esquema para el despacho económico óptimo de MRs con calor y energía combinados (*combined heat and power*, CHP), que incorpora un problema de despacho económico basado en aritmética afín en un marco de MPC [91]. En este

esquema se utiliza la predicción de la demanda para el problema de optimización, pero no se realiza gestión de la demanda. En [92], se desarrolla una estrategia basada en programación lineal entera mixta (MILP, por sus siglas en inglés) para gestionar las cargas en un edificio residencial con operación aislada, integrando generación fotovoltaica y almacenamiento en baterías. Esta técnica permite programar el encendido de las cargas controlables en cada período según un esquema de prioridad y teniendo en cuenta el estado de carga de las baterías, la generación solar disponible y el nivel de confort deseado por el usuario. Los autores de [93] desarrollan dos estrategias de MPC para la gestión conjunta del despacho de generación y la demanda de sistemas de HVAC en una casa aislada de la red, que se consideró como una única zona térmica. Estas estrategias, en comparación con una lógica de control basada en reglas (*rule-based control*, RBC), resultaron prometedoras, pero la optimización presentada es muy compleja para ser implementada en sistemas embebidos.

Otros trabajos también han propuesto la gestión conjunta de la generación y la demanda, pero en MRs conectadas a la red, utilizando diferentes métodos de optimización. En [94], se propone un MPC para controlar el sistema de HVAC de un edificio que incorpora un concentrador solar para cogeneración a escala micro. Este control basado en MPC minimiza el consumo de electricidad de la red principal mediante la optimización del almacenamiento de energía térmica, la conversión de energía en el ciclo Rankine orgánico y el flujo de energía térmica con el sistema de HVAC. Por otro lado, los autores de [49] desarrollan un control predictivo para reducir la demanda máxima a través de la gestión de los equipos de HVAC, las baterías y la generación renovable, cumpliendo también con los requisitos de confort térmico de varias zonas de un edificio. El controlador tiene en cuenta la temperatura externa, el precio de la tarifa eléctrica y el confort requerido para ajustar el funcionamiento de las baterías, los paneles fotovoltaicos y la temperatura de los termostatos en cada sala. Sin embargo, esta estrategia proporciona un control indirecto del sistema de HVAC a través de los puntos de ajuste de los termostatos de la zona, cumpliendo con un modelo de confort humano que es mucho más flexible que un rango de temperatura ajustado. Un esquema similar de MPC para la gestión de energía en edificios se propone en [95], integrado por un sistema HVAC centralizado que controla múltiples zonas, dos bombas de calor para calefacción y refrigeración, y almacenamiento de energía térmica en agua caliente. El controlador determina el intercambio de energía con la batería, la temperatura de ajuste y el flujo de aire de cada zona. El objetivo del controlador es minimizar el monto de la factura de electricidad, resolviendo

problemas de programación lineal (LP) y programación lineal entera mixta (MILP) muy complejos.

Por el contrario, en este capítulo se desarrolla un esquema sencillo de MPC para el control directo de las potencias de la MR, resultando en una optimización viable para sistemas embebidos. Este esquema de MPC se aplica a la gestión conjunta del despacho de generación híbrida y de las cargas controlables (particularmente, de los equipos de HVAC) tanto para MRs conectadas o aislada de la red. Los recursos de energía distribuidos (generación y almacenamiento) y los equipos HVAC (cargas controlables) se gestionan simultáneamente para mejorar el rendimiento de las microrredes sin perder el confort térmico. Se aplican estrategias de DSM de manera explícita (actuando sobre las cargas controlables) e implícita (optimizando la operación del sistema utilizando su inercia térmica). A diferencia de [49], [90], [91], [92], [93], [94], [95], la novedad del esquema de MPC propuesto radica en que éste utiliza modelos LPV para el sistema HVAC/banco de baterías, y predicciones aproximadas de 24 horas (basadas en modelos de pronóstico simples) de la temperatura externa, la generación renovable y la demanda no controlable, para controlar directamente las potencias de la MR.

El esquema de MPC presentado en este capítulo tiene múltiples objetivos que incluyen (i) gestión del confort térmico en una sola zona o múltiples zonas, teniendo en cuenta las temperaturas de las salas contiguas, (ii) reducción de picos de demanda y desplazamiento de carga, (iii) control de almacenamiento de energía en baterías, y (iv) utilización óptima de la energía renovable. El esquema desarrollado se aplica a dos casos de estudio de interés regional, una granja avícola automatizada (aislada de la red) y un centro de salud (conectado a la red) que posee un elevado monto en la factura eléctrica debido a penalizaciones. Para el primer caso de estudio (MR aislada de la red), el objetivo es maximizar el uso de la generación fotovoltaica mediante la gestión inteligente de las baterías y el sistema HVAC, además de minimizar el uso del generador diésel y mantener el confort térmico. Para el segundo caso de estudio, la MR conectada a la red integra paneles fotovoltaicos, baterías, equipos de HVAC y cargas no controlables. El objetivo en este caso es limitar la demanda de la red de distribución a la demanda máxima permitida para evitar penalizaciones tarifarias (y así reducir los costos de electricidad en general), manteniendo el confort térmico.

La formulación del controlador propuesto para la MR aislada difiere de [90], [91], [92], [93] en que incluye tanto el control de temperatura de la sala como el seguimiento del SoC de las baterías. De este modo, la gestión de la energía es más eficiente al considerar el sistema térmico como un dispositivo de almacenamiento adicional, permitiendo que la temperatura varíe dentro

de un cierto rango en función de la predicción de generación renovable, cargas no controlables y temperatura exterior. Por otro lado, la formulación del MPC propuesto para la MR conectada a la red difiere de [49], [94], [95] en que gestiona las potencias de los equipos HVAC para evitar exceder la demanda permitida a través del control de temperatura de las zonas consideradas.

Este capítulo se organiza de la siguiente manera: en la Sección 3.3 se expone la problemática de las dos MRs bajo estudio. Además, se presenta el modelo térmico utilizado para los sistemas HVAC. En la Sección 3.4, se describen los esquemas de control propuestos para ambos casos de estudio, formulando los problemas de optimización a resolver y detallando el control de zona propuesto basado en modelos simples de predicción. En la misma sección se detallan los modelos de predicción de perturbaciones utilizados. La Sección 3.5 muestra simulaciones de las estrategias de control propuestas, aplicadas a cada caso de estudio. Además, se realiza una discusión de los beneficios económicos, se aborda la evaluación del rendimiento y la robustez del control, así como una comparación con otras técnicas de control existentes. Por último, en la Sección 3.6, se proporcionan algunas conclusiones del trabajo.

3.3 Problemas de estudio

El objetivo de esta sección es describir los dos problemas que se resuelven en este capítulo, asociados a dos MRs distintas. El primer caso de estudio es una granja avícola automatizada, que opera de manera aislada de la red de distribución; el segundo caso, es el centro de salud, descrito anteriormente en la Sección 2.4, que tiene un elevado costo de energía debido a que su demanda a la red supera un umbral determinado.

La cría de aves de corral es una actividad muy desarrollada en la provincia de Entre Ríos, en la que se está incorporando cada vez más tecnología para reducir costos operativos y aumentar la productividad. La automatización de las granjas avícolas, junto con el control de la iluminación artificial y de la temperatura, reducen la mortalidad de los animales y aumenta el rendimiento de la producción, pero requiere mucha energía. En este sentido, la utilización de generación renovable junto con estrategias eficientes de despacho y de gestión de la demanda en las granjas avícolas puede ser una solución rentable, particularmente para aquellas alejadas de la red.

El CS representa una gran demanda de energía, solicitando picos de potencia a la red cercanos al máximo permitido por la tarifa contratada (300 kW en este caso), como se describe en la Sección 2.4 [96]. Este centro tiene dos inconvenientes: el elevado costo de energía debido

a las penalizaciones (o recargos) por sobrepasar el umbral de 300 kW de potencia del cuadro tarifario [96] y el requisito legal de consumir un porcentaje de energía provenientes de fuentes renovables por solicitar potencias a red superiores a 300 kW [71] (apartado 2.4.1).

3.3.1 Microrred 1

Esta MR se compone por generación diésel, generación fotovoltaica, baterías, cargas controlables y cargas no controlables (también llamadas demanda despachable y demanda base, respectivamente), considerando a los equipos HVAC como cargas controlables. Por lo tanto, los subsistemas a controlar son dos: el banco de baterías y el equipo HVAC. Se considera que la puesta en marcha y el apagado del generador diésel son instantáneos.

La Figura 3.1 describe la topología de la MR, mostrando las conexiones de los componentes al bus de alterna (AC) y continua (DC).

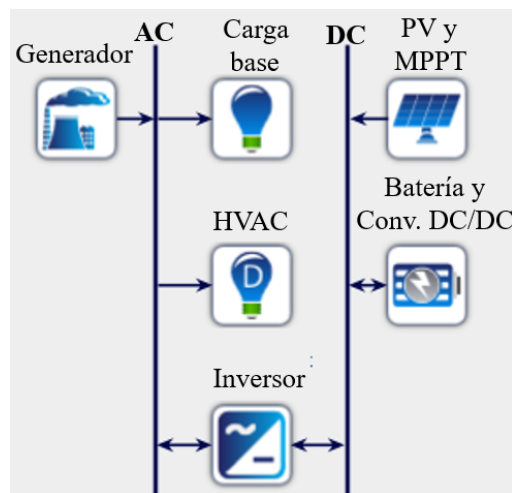


Figura 3.1. Topología de la microrred 1.

Se utiliza el modelo térmico análogo a un circuito RC presentado en el apartado 2.3.2. En este caso, el galpón cuenta con una única zona, por lo que no se consideran los efectos de salas contiguas. Además, se desprecian las fuentes internas de calor ($P_s=0$) y se considera que los equipos HVAC pueden operar tanto para refrigerar como para calefaccionar. El modelo se aprecia en la Figura 3.2. T_i , T_e , y P_D representan la temperatura interna, la temperatura externa y la potencia térmica del equipo HVAC, respectivamente. η es el CoP del sistema de climatización y en el modelo su signo indica el modo de operación (calefacción o refrigeración). Cuando la fuente de corriente suministra potencia al nodo T_i , el equipo funciona como sistema de calefacción, mientras que cuando la fuente de corriente extrae potencia del nodo, el equipo funciona como sistema de refrigeración.




Figura 3.2. Modelo eléctrico RC equivalente para un sistema de climatización (funcionando como calefacción).

A partir del circuito de la Figura 3.2, se obtiene la siguiente ecuación diferencial:

$$\frac{dT_i}{dt} = -\frac{T_i}{RC} + \frac{\eta P_D}{C} + \frac{T_e}{RC} \quad (3.1)$$

donde R es la resistencia térmica de la sala, C es la capacidad de almacenamiento de calor o frío de la sala. η_c y η_h son el CoP del equipo funcionando para refrigeración y calefacción, respectivamente. En este esquema, se asume que la potencia eléctrica P_D del sistema HVAC es una variable manipulada y continua.

Teniendo en cuenta que los equipos de climatización son frío/calor y que la temperatura de referencia es de 24 °C, se tiene que:

$$\eta = \begin{cases} -\eta_c, & \text{si } T_e \geq 24 \\ \eta_h, & \text{si } T_e < 24 \end{cases} \quad (3.2)$$

El balance de potencia de la MR indica que la demanda debe ser igual a la potencia generada por los diferentes recursos distribuidos. Por lo tanto:

$$P_D + P_{ND} = P_{PV} + P_B + P_G \quad (3.3)$$

siendo P_{ND} es la demanda base dada por el consumo de iluminación, circuito de tomas, etc. P_{PV} es la potencia suministrada por los paneles fotovoltaicos, P_B es la potencia de carga/descarga del banco de baterías (que es positiva durante la descarga, cuando entrega energía; y es negativa durante la carga, cuando las baterías almacenan energía) y P_G es la potencia suministrada por el generador diésel. Por simplicidad, se asumió que la eficiencia del inversor es unitaria.

3.3.2 Microrred 2

Este caso de estudio considera al centro de salud descrito en la Sección 2.4 como una MR con conexión a red, pero que además incorpora baterías y opcionalmente paneles fotovoltaicos (Figura 3.3).

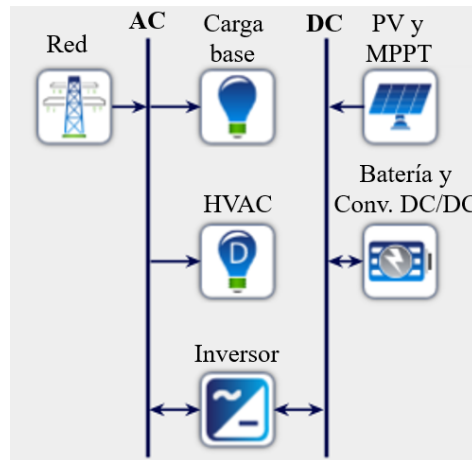


Figura 3.3. Topología de la microrred 2.

El flujo de potencia intercambiado entre el bus de DC y el banco de baterías puede ajustarse utilizando el convertidor DC/DC asociado, por lo que P_B es una variable manipulada. Toda la energía fotovoltaica disponible se inyecta en la MR, de modo que la potencia suministrada por los paneles solares P_{PV} no es una variable manipulada, sino una perturbación medida. La demanda base P_{ND} y la temperatura exterior T_e también se consideran como perturbaciones medidas.

Los modelos térmicos del CS propuestos en el Capítulo 2 y 3 son similares. Sin embargo, en este capítulo no se consideran fuentes internas de calor y se divide al centro de salud en 3 grandes zonas (Figura 3.4). Esta simplificación permite incrementar la controlabilidad del modelo y así garantizar la estabilidad asintótica del MPC.

Se utiliza un modelo más sencillo para incrementar la controlabilidad del modelo y así la estabilidad asintótica del MPC.

El modelo térmico asociado se describe mediante el siguiente sistema de ecuaciones diferenciales:

$$\begin{aligned}
 \frac{dT_1}{dt} &= \frac{\eta P_1}{C_1} + \frac{T_e - T_1}{R_1 C_1} + \frac{T_2 - T_1}{R_{12} C_1} \\
 \frac{dT_2}{dt} &= \frac{\eta P_2}{C_2} + \frac{T_e - T_2}{R_2 C_2} + \frac{T_1 - T_2}{R_{12} C_2} + \frac{T_3 - T_2}{R_{23} C_2} \\
 \frac{dT_3}{dt} &= \frac{\eta P_3}{C_3} + \frac{T_e - T_3}{R_3 C_3} + \frac{T_2 - T_3}{R_{23} C_3}
 \end{aligned} \tag{3.4}$$

donde T_1 , T_2 y T_3 son las temperaturas internas de las zonas 1, 2 y 3, respectivamente; cada par (R_1, C_1) , (R_2, C_2) y (R_3, C_3) consta de la resistencia y capacidad térmica de cada zona. R_{12} y R_{13} son las resistencias térmicas compartidas entre zonas contiguas. Luego, P_1 , P_2 y P_3 son las potencias eléctricas necesarias para producir las cargas térmicas a suministras en las zonas 1, 2 y 3, respectivamente. En este esquema, se asume que las tres potencias eléctricas de los sistemas HVAC son variables que pueden ser manipuladas de manera continua.

Planteando el balance de potencia en el bus AC de la MR, la demanda de las cargas debe ser igual a la potencia suministrada por los diferentes generadores. También se desea que la potencia demandada a la red principal P_{MG} no exceda la potencia umbral permitida (en este caso, es deseable que $P_{MG} \leq 300$ kW). P_{MG} no es una variable manipulada, pero la restricción sobre ella puede expresarse como una combinación lineal de variables manipuladas y de perturbaciones medidas relacionadas:

$$P_{MG} = P_1 + P_2 + P_3 + P_{ND} - P_B - P_{PV} \leq 300 \quad (3.5)$$




Figura 3.4. Subdivisión del centro de salud en tres grandes zonas.

3.4 Soluciones propuestas

De manera general, las soluciones propuestas se basan en la gestión conjunta del despacho de generación híbrida y de la gestión de la demanda de equipos HVAC, utilizando un esquema de control predictivo. La generación renovable y la demanda base son las principales perturbaciones que actúan en las MRs consideradas. Si se dispone de conocimiento sobre la evolución futura de las perturbaciones, el MPC puede utilizarlo para predecir la salida del sistema a lo largo del horizonte de predicción. La formulación del MPC propuesto utiliza modelos simples de predicción de las perturbaciones medidas de manera de mejorar el control de avance y retroalimentación. También utiliza el control de zonas para permitir una gestión óptima en el lado de la demanda, aprovechando la predicción futura del comportamiento del sistema. Esta sección presenta cómo el MPC de zonas puede integrar el conocimiento de las

perturbaciones para anticipar su efecto y mejorar el rendimiento de la microrred. El algoritmo de control propuesto se basa en predicciones de generación fotovoltaica, demanda base y temperatura exterior, y en la capacidad del MPC para manejar grandes diferencia planta-modelo. En particular, se desarrolla una formulación para cada caso de estudio.

La solución propuesta para el caso de estudio 1 consiste en gestionar los recursos para maximizar el uso de la generación fotovoltaica, a través de la gestión inteligente de las baterías y del sistema HVAC, minimizando el uso del generador diésel. El principal propósito de las baterías es almacenar el exceso de energía de los paneles durante el día para utilizarla por la noche, mientras que el propósito de gestionar la potencia del sistema HVAC es permitir estrategias de gestión de la demanda mediante la inercia térmica prevista del sistema, con el objetivo de utilizar la energía mínima necesaria para mantener el confort térmico requerido (22 - 26 °C).

La solución propuesta para el caso 2 de estudio consiste en integrar un banco de baterías y opcionalmente paneles fotovoltaicos a una MR conectada a la red, de manera que la demanda de potencia a la red sea menor a 300 kW y se mantenga el confort térmico en un rango de temperatura (23 - 25 °C). El principal propósito de las baterías es proporcionar la energía necesaria para evitar exceder la demanda de 300 kW permitida desde la red en días de alta demanda y baja generación solar, mientras que el propósito de gestionar la potencia del sistema HVAC es permitir estrategias de respuesta a la demanda para no exceder este límite de demanda sin perder el confort térmico. La gestión energética determina la potencia eléctrica necesaria para climatizar cada zona, así como para controlar la carga y descarga de las baterías para evitar picos.

A continuación, se describen las predicciones simples a utilizar y las dos formulaciones de MPC propuestas.

3.4.1 Predicciones

Para los casos de estudio, se requiere la predicción de temperatura exterior T_e , de la generación fotovoltaica disponible P_{aPV} y la demanda base P_{ND} . En estos casos, no se consideran las fuentes internas de calor, es decir, el calor generado por humanos y cargas se considera nulo. Para la predicción de T_e y P_{ND} , se utilizan los mismos modelos desarrollados en el apartado 2.3.5 que se basan en reconciliación de nivel. Por el contrario, la generación fotovoltaica P_{aPV} tiene una línea de base nula, por lo que se utiliza reconciliación de escala.

$$\hat{P}_{aPV}(k+j|k) = \left(\frac{P_{aPV}(k)}{\bar{P}_{aPV}(k \bmod N_e)} \right) \bar{P}_{aPV}(k + \text{mod}(j, N_e)) \quad (3.6)$$

donde $\bar{P}_{aPV}(\cdot)$ es el perfil de generación fotovoltaica, $P_{aPV}(k)$ es la medición actual y mod es el operador residuo. El valor actual de la potencia fotovoltaica disponible $P_{aPV}(k)$ se obtiene a partir de la fórmula que utiliza la medición de irradiancia y temperatura [8]. El perfil promedio se genera utilizando la misma fórmula y la base datos de irradiancia de HOMER Pro®. El perfil promedio diario varía mes a mes.

3.4.2 Formulación del MPC para la microrred 1 (aislada)

Considerando un retenedor de orden cero, la ecuación diferencial (3.1) se discretiza para un tiempo de muestreo t_s . Luego, se agrega el modelo discreto del SoC de las baterías [8] al sistema, así como el equilibrio entre la generación y la demanda en el bus de CA (3.3). Finalmente, se obtiene el siguiente sistema de ecuaciones:

$$\begin{aligned} T_i(k+1) &= a_{11}T_i(k) + b_{11,k}P_D(k) + d_{11}T_e(k) \\ SoC(k+1) &= SoC(k) - b_{22,k}P_B(k) \\ P_D(k) + P_{ND}(k) &= P_{PV}(k) + P_B(k) + P_G(k) \end{aligned} \quad (3.7)$$

con

$$\begin{aligned} b_{11,k} &= \begin{cases} -b_{11}, & \text{si } T_e(k) \geq 24 \\ b_{11}, & \text{si } T_e(k) < 24 \end{cases} \\ b_{22,k} &= \begin{cases} \frac{t_s}{(E_{max} \eta_{bd})}, & \text{si } P_B(k) \geq 0 \\ \frac{\eta_{bc} t_s}{E_{max}}, & \text{si } P_B(k) < 0 \end{cases} \end{aligned} \quad (3.8)$$

donde η_{bc} y η_{bd} son las eficiencias de carga y descarga del banco de baterías, respectivamente y E_{max} es su capacidad máxima de almacenamiento de energía. En (3.8), T_e y P_{ND} se consideran perturbaciones medidas. En esta MR, el banco de baterías es el responsable de regular el voltaje del bus DC (a través de un convertidor con su propio control), absorbiendo o inyectando energía según exista exceso o déficit en la generación, respectivamente; por lo tanto, $P_B(k)$ no es una variable manipulada. Sin embargo, puede expresarse como una combinación lineal de las otras variables manipuladas y de las perturbaciones medidas:

$$P_B(k)=P_D(k)+P_{ND}(k)-P_{PV}(k)-P_G(k) \quad (3.9)$$

Reemplazando la igualdad de (3.9) en (3.7), se obtiene el siguiente sistema lineal de parámetros variables (LPV):

$$\begin{aligned} T_i(k+1) &= a_{11}T_i(k) + b_{11,k}P_D(k) + d_{11}T_e(k) \\ SoC(k+1) &= SoC(k) - b_{22,k}(P_D(k) + P_{ND}(k) - P_{PV}(k) - P_G(k)) \end{aligned} \quad (3.10)$$

Reorganizando en una ecuación vectorial-matricial, se obtiene la siguiente representación, en espacio de estados, del sistema:

$$\begin{aligned} \begin{bmatrix} T_i(k+1) \\ SoC(k+1) \end{bmatrix} &= \begin{bmatrix} a_{11} & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} T_i(k) \\ SoC(k) \end{bmatrix} + \begin{bmatrix} 0 & 0 & b_{11,k} \\ b_{22,k} & b_{22,k} & -b_{22,k} \end{bmatrix} \begin{bmatrix} P_{PV}(k) \\ P_G(k) \\ P_D(k) \end{bmatrix} \\ &+ \begin{bmatrix} d_{11} & 0 \\ 0 & -b_{22,k} \end{bmatrix} \begin{bmatrix} T_e(k) \\ P_{ND}(k) \end{bmatrix} \end{aligned} \quad (3.11)$$

$$x(k+1) = Ax(k) + B(\rho_k)u(k) + D(\rho_k)d(k)$$

donde $x(k+1)$ es el vector de estados en el paso $k+1$, $u(k)$ es el vector de variables manipuladas en el paso anterior, $d(k)$ es el vector de variables de perturbación medidas y $\rho_k = [b_{11,k}, b_{22,k}]$ es el vector de variables de programación (o el vector de parámetros de la variable temporal); definido en (3.8). La salida $y(k)$ coincide con el estado $x(k)$, por lo que la matriz C es igual a la identidad.

En esta formulación, se propone un control de zona para T_i y un seguimiento del SoC . El control de zona permite que T_i varíe en una zona de confort (o intervalo) $[T_{i,zona}^{min}, T_{i,zona}^{max}]$, reduciendo así la demanda de potencia P_D cuando P_{ND} es alta y/o P_{PV} es baja. El seguimiento de una referencia constante a trozos de SoC , construida a partir de las predicciones futuras de generación y demanda no despachable, permite almacenar energía de forma preventiva en el banco de baterías durante el día para utilizarla durante la noche. Estos objetivos de control se logran mediante la combinación de MPC para seguimiento [97] (aplicado a SoC) con MPC para seguimiento de zonas [98], [99] (aplicado a T_i) en la misma formulación.

El método de MPC para seguimiento se basa en la adición de un estado estacionario artificial y una entrada (x_a, u_a) como variables de decisión, el uso de una función de costo modificada y

una restricción terminal de estabilización. Este diseño de control incorpora una referencia artificial al problema de optimización y establece que los estados del sistema deben seguir esta variable artificial. Además, se determina que este punto de referencia artificial debe estar lo más cerca posible de la referencia de estado estacionario real x_s , lo que garantiza en conjunto un dominio de atracción ampliado [100]. De esta manera, el controlador garantiza el cumplimiento de las restricciones y la evolución asintótica del sistema hacia cualquier objetivo en una trayectoria admisible a partir de cualquier estado inicial factible $x(k)$. Por lo tanto, se pueden seguir secuencias de puntos de referencia admisibles a trozos sin error. Si el punto de operación objetivo (x_s, u_s) no es un estado estacionario admisible para (3.11), el controlador guía el sistema hacia el estado estacionario admisible más cercano. La versión de MPC para seguimiento de zonas también permite que el estado controlado varíe dentro de una zona que incluye el objetivo de acuerdo con las necesidades del sistema.

Es importante destacar que el problema de optimización estándar de MPC para el modelo LPV considerado en (3.7) y (3.8) tiene que elaborar internamente la restricción de predicción del modelo de (3.11), que presenta no linealidades a partir de la segunda iteración. En consecuencia, este hecho convierte el problema estándar de MPC en un problema de programación no lineal (NLP, por sus siglas en inglés).

Asunción 1. El valor de referencia futuro (o el valor deseado futuro) del *SoC* del banco de baterías se establece en función de las predicciones de P_{aPV} y P_{ND} de la siguiente manera:

$$\widehat{SoC}_s(k+j|k) = \begin{cases} SoC_{max}, & \text{si } \widehat{P}_{aPV}(k+j|k) \geq \widehat{P}_{ND}(k+j|k) \\ SoC_{min}, & \text{si } \widehat{P}_{aPV}(k+j|k) < \widehat{P}_{ND}(k+j|k) \end{cases} \quad (3.12)$$

De esta manera, si la predicción de potencia fotovoltaica disponible es mayor que la de demanda no despachable, el exceso de energía se utiliza para cargar las baterías, estableciendo la referencia futura del *SoC* como el valor máximo posible. Por el contrario, si la predicción de demanda no despachable es mayor a la de generación fotovoltaica, el déficit de energía es abastecido por las baterías, estableciendo la referencia futura del *SoC* como el mínimo admisible.

Asunción 2. Cuando el problema de MPC se aplica al proceso descrito con un modelo LPV, se necesita describir la evolución de las variables de programación a lo largo del horizonte de predicción N para obtener los valores futuros de los estados. Se asume que el vector de variables de programación ρ_k es conocido para todos los instantes futuros dentro del horizonte N . Al

hacerlo, las predicciones basadas en el modelo LPV en un problema de MPC pueden convertirse en una formulación más simple. La estrategia de estimación simple presentada en (3.6) y (3.12) se utiliza para proporcionar una suposición fija $\hat{\rho}_k$ en cada instante k en lugar de ρ_k en el problema de MPC. Dado que no hay valores futuros predichos de P_B (ver (3.10)), se reemplazan por una predicción futura relacionada, los valores futuros de $SoCs$ (punto de consigna del banco de baterías). Luego, los componentes del vector $\hat{\rho}_{k+j}$ para j de 1 a N se predicen de la siguiente manera:

$$\hat{b}_{11,k+j} = \begin{cases} -b_{11}, & \text{si } \hat{T}_e(k+j|k) \geq 24 \\ b_{11}, & \text{si } \hat{T}_e(k+j|k) < 24 \end{cases}$$

$$\hat{b}_{22,k+j} = \begin{cases} \frac{t_s}{E_{max}\eta_{bd}}, & \text{si } \widehat{SoC}_s(k+j|k) = SoC_{min} \\ \frac{\eta_{bc}t_s}{E_{max}}, & \text{si } \widehat{SoC}_s(k+j|k) = SoC_{max} \end{cases} \quad (3.13)$$

Si se asume que el vector de variables de programación ρ_k es conocido a lo largo de N , el problema de programación no lineal (NLP) se convierte en una versión de programación cuadrática (QP), lo cual permite una evaluación mucho más rápida que los procedimientos completos de MPC no lineal.

Asunción 3. Considerando $Q \in \mathbb{R}^{xxx}$ y $R \in \mathbb{R}^{uxu}$ como matrices definidas positivas (de x por x y u por u , respectivamente) y K como una ganancia de control retroalimentado de estado arbitrario que estabiliza el modelo del sistema. Para estas matrices, se entiende que, para el modelo LPV en tiempo discreto, $A+B(\rho_k)K$ es Schur [101]. Entonces, existe otra matriz definida positiva $P \in \mathbb{R}^{xxx}$ tal que:

$$(A+B(\rho_k)K)'P(A+B(\rho_k)K)-P=-(Q+K'RK) \quad (3.14)$$

Se cumple para todo $\rho_k \in \Pi$, donde Π es un conjunto convexo finito (se omite el vector de perturbación $d(k)$).

Entonces, siempre y cuando se cumplan las asunciones anteriores, el problema de MPC se formula con la siguiente función de costo:

$$V_N(x(k), \mathbf{u}, \mathbf{x}_a, \mathbf{u}_a) = \sum_{j=0}^{N-1} \|x(k+j) - x_a(k+j)\|_Q^2 + \sum_{j=0}^{N-1} \|u(k+j) - u_a(k+j)\|_R^2 + \|x(k+N) - x_a(k+N)\|_P^2 + \|x_a(k+N) - x_s\|_T^2 \quad (3.15)$$

donde:

$$\begin{aligned} x_a(k+j) &= [T_{i,a}, \widehat{SoC}_s(k+j|k)]', \\ u_a(k+j) &= [\widehat{P}_{aPV}(k+j|k), 0, 0]', \\ x_s &= [T_{i,s}, \widehat{SoC}_s(k+N|k)]', \end{aligned} \quad (3.16)$$

En esta función de costo $V_N(\cdot)$, $(x_a(k+j), u_a(k+j))$ define un objetivo de regulación artificial y el término $\|x(k+N) - x_a(k+N)\|_P^2$ es un desplazamiento que penaliza la desviación del estado final de esta operación objetivo. Además, el término de desplazamiento $\|x_a(k+N) - x_s\|_T^2$ con $T=10P$ (T y P matrices de ponderación de las normas) asegura que la variable artificial siga la variable de consigna real, con la meta real definida por (x_s, u_s) . Es importante destacar que la inclusión de esta penalización adecuada del estado terminal $x(k+N)$ puede conducir a la estabilidad asintótica con buenos resultados, como se evidencia en [98]. Esta función de costo tiene un control de zona para el estado x_1 y un seguimiento de consigna para el estado x_2 . $u_{1,a}$ y $x_{2,a}$ varían a lo largo del horizonte de predicción, mientras que $x_{1,a}$ es una variable única para todo el horizonte. El valor N establece el límite de los instantes de tiempo en los que se desea que la salida siga la referencia.

Los componentes de la MR tienen limitaciones físicas y operativas que deben tenerse en cuenta para el problema de optimización. Las limitaciones de los equipos en términos de límites y variaciones de potencia se incluyen para optimizar la eficiencia y la vida útil. El banco de baterías debe operar en un rango de valores de SoC para evitar la sobrecarga y la descarga excesiva que reducen notablemente el número de ciclos admisibles. Aunque la potencia intercambiada por el banco de baterías no es una variable manipulada, sus limitaciones se pueden expresar en términos de las otras variables manipuladas, considerando la expresión de $P_B(k)$ en (3.9). El problema de optimización a resolver en cada paso es el siguiente:

$$V_N^*(x(k)) = \min_{\mathbf{u}, \mathbf{x}_a, \mathbf{u}_a} V_N(x(k), \mathbf{u}, \mathbf{x}_a, \mathbf{u}_a) \quad (3.17)$$

s.a

$$\begin{aligned}
x(k+j+1) &= Ax(k+j) + B(\hat{\rho}_{k+j})u(k+j) + D(\hat{\rho}_{k+j})\hat{d}(k+j|k), \forall j \in \mathbf{Z}^+_{[0, N-1]}, \\
0 \leq u_1(k+j) &\leq \hat{P}_{aPV}(k+j|k), \forall j \in \mathbf{Z}^+_{[0, N-1]}, \\
-(SoC_{max} - x_2(k+j))E_{max}/t_s &\leq u_3(k+j) + \hat{P}_{ND}(k+j|k) - u_1(k+j) - u_2(k+j) \\
&\leq (x_2(k+j) - SoC_{min})E_{max}/t_s, \forall j \in \mathbf{Z}^+_{[0, N-1]}, \\
x^{min} \leq x(k+j+1) &\leq x^{max}, u^{min} \leq u(k+j) \leq u^{max}, \forall j \in \mathbf{Z}^+_{[0, N-1]}, \\
x_a(k+N) &= Ax_a(k+N) + B(\hat{\rho}_{k+N})u_a(k+N-1) + D(\hat{\rho}_{k+N})\hat{d}(k+N-1) \\
u^{min} \leq u_a(k+j) &\leq u^{max}, x_{zona}^{min} \leq x_a(k+j) \leq x_{zona}^{max}, \forall j \in \mathbf{Z}^+_{[0, N-1]}, \\
x(k+N) &= x_a(k+N)
\end{aligned}$$

con:

$$\hat{d}(k+j|k) = [\hat{T}_e(k+j|k), \hat{P}_{ND}(k+j|k)]', \quad (3.18)$$

donde N es el horizonte de predicción y control. La solución a este problema es una secuencia de acciones de control \mathbf{u}^* , pero solo se implementa la primera acción de control de \mathbf{u}^* . El siguiente paso resuelve el mismo problema con mediciones actualizadas y así sucesivamente. Esto se conoce como control de horizonte deslizante. Las acciones de control a implementar, obtenidas a partir del problema de optimización anterior, son los puntos de consigna de los generadores ($P_{PV}(k)$, $P_G(k)$) y el punto de operación del sistema HVAC ($P_D(k)$). De hecho, cuando se cumplen las asunciones anteriores, es posible implementar este esquema de MPC en procesadores embebidos utilizando un solucionador de QP rápido y robusto [102].

3.4.3 Formulación del MPC de la microrred 2 (con conexión a la red)

Discretizando (3.4) para un tiempo de muestreo t_s , se obtiene la siguiente representación discreta de espacio de estados: A_d , B_d , D_d . Luego, considerando también el modelo del banco de baterías, se obtiene la siguiente representación de espacio de estados del sistema:

$$\begin{aligned}
x(k+1) &= \begin{bmatrix} A_d & 0_{3 \times 1} \\ 0_{1 \times 3} & 1 \end{bmatrix} x(k) + \begin{bmatrix} B_d & 0_{3 \times 1} \\ 0_{1 \times 3} & b_{44} \end{bmatrix} u(k) + \begin{bmatrix} D_d & 0 \\ 0 & 0 \end{bmatrix} d(k) \\
x(k+1) &= Ax(k) + B(\rho_k)u(k) + D(\rho_k)d(k)
\end{aligned} \quad (3.19)$$

donde:

$$\begin{aligned} x(k) &= [T_1(k), T_2(k), T_3(k), SoC(k)]', \\ u(k) &= [P_1(k), P_2(k), P_3(k), P_B(k)]', \\ d(k) &= [T_e(k), P_{ND}(k) - P_{PV}(k)]', \end{aligned} \quad (3.20)$$

Este modelo LPV tiene un vector de variables de programación $\rho_k = [b_{11,k}, b_{22,k}, b_{33,k}, b_{44,k}]$ con las siguientes cuatro variables:

$$\begin{aligned} b_{11,k} &= \begin{cases} -b_{11}, & \text{si } T_e(k) \geq 24 \\ b_{11}, & \text{si } T_e(k) < 24 \end{cases}, & b_{22,k} &= \begin{cases} -b_{22}, & \text{si } T_e(k) \geq 24 \\ b_{22}, & \text{si } T_e(k) < 24 \end{cases}, \\ b_{33,k} &= \begin{cases} -b_{33}, & \text{si } T_e(k) \geq 24 \\ b_{33}, & \text{si } T_e(k) < 24 \end{cases}, & b_{44,k} &= \begin{cases} \frac{t_s}{(E_{max} \eta_{bd})}, & \text{si } P_B(k) \geq 0 \\ \frac{\eta_{bc} t_s}{E_{max}}, & \text{si } P_B(k) < 0 \end{cases} \end{aligned} \quad (3.21)$$

Observar que $B(\rho_k) = \text{diag}([b_{11,k}, b_{22,k}, b_{33,k}, b_{44,k}])$. Este modelo ((3.19) - (3.21)) asume que la MR tiene un convertidor DC/DC para cargar y descargar las baterías que puede ser manipulado. Otra opción es manipular la potencia intercambiada con la red principal. En esta MR, el banco de baterías se utiliza para compensación, evitando así una demanda de potencia mayor a 300 kW (demanda de potencia máxima permitida). La potencia intercambiada con la red principal no es una variable manipulada, pero la restricción correspondiente puede expresarse como una combinación lineal de las otras variables manipuladas y perturbaciones medidas basada en el equilibrio entre la generación y la demanda, de la siguiente manera:

$$u_1(k) + u_2(k) + u_3(k) - u_4(k) + d_2(k) \leq 300 \quad (3.22)$$

donde $d_2(k) = P_{ND}(k) - P_{PV}(k)$ es una perturbación medida compuesta por la demanda no controlable P_{ND} y la potencia suministrada por los paneles solares P_{PV} . Por otro lado, los desplazamientos (diferencias entre las salidas y los puntos de consigna) pueden ser causados por discrepancias entre el modelo y la planta. Para lograr un control sin desplazamientos, el modelo puede expresarse en forma incremental utilizando el incremento de control $\Delta u(k)$ como la entrada, en lugar de la señal de control $u(k)$. Este modelo se puede escribir en la forma general de espacio de estados considerando que $\Delta u(k) = u(k) - u(k-1)$. Luego, si esta expresión se incluye en (3.19), se puede obtener la siguiente representación:

$$\begin{bmatrix} x(k+1) \\ u(k) \end{bmatrix} = \begin{bmatrix} A & B(\rho_k) \\ 0_{4 \times 4} & I \end{bmatrix} \begin{bmatrix} x(k) \\ u(k-1) \end{bmatrix} + \begin{bmatrix} B(\rho_k) \\ I \end{bmatrix} \Delta u(k) + \begin{bmatrix} D(\rho_k) \\ 0_{4 \times 2} \end{bmatrix} d(k) \quad (3.23)$$

Además, si se introduce un nuevo vector de estado $\tilde{x}(k) = [x(k), u(k-1)]'$ en (3.23), el modelo incremental toma la siguiente forma general:

$$\tilde{x}(k+1) = M(\rho_k)\tilde{x}(k) + N(\rho_k)\Delta u(k) + N_d(\rho_k)d(k) \quad (3.24)$$

En esta formulación, se propone un control de zona para T_1 , T_2 , T_3 y SoC utilizando MPC para el seguimiento de zonas [98], [99]. La forma en que este controlador maneja el problema de seguimiento se caracteriza por: (i) considerar un estado estacionario y una entrada artificiales como variables de decisión (x_a, u_a) , (ii) penalizar la desviación de la trayectoria predicha con las condiciones estacionarias artificiales, (iii) agregar una función de costo de desplazamiento para penalizar la desviación entre el punto de equilibrio artificial y el objetivo, y (iv) considerar una restricción terminal de estabilización.

Se considera una región del sistema ((3.19) - (3.21)) definida por $\{x_a : x_{a,zona}^{min} \leq x_a \leq x_{a,zona}^{max}\}$, y se define el punto de operación deseado dentro de dicha región, típicamente en el centro de la zona. Luego, siempre que se cumpla la *asunción* 3 y se puedan predecir las variables de programación ρ_k según la (3.13), el problema de MPC se formula con la siguiente función de costo:

$$V_N(\tilde{x}(k), \Delta \mathbf{u}, x_a, u_a) = \sum_{j=0}^{N-1} \|\tilde{x}(k+j) - \tilde{x}_a\|_{\tilde{Q}}^2 + \sum_{j=0}^{N_c-1} \|\Delta u(k+j)\|_S^2 + \|x(k+N) - x_a\|_P^2 + \|x_a - x_s\|_T^2 \quad (3.25)$$

donde $\Delta \mathbf{u}$ es la secuencia de incrementos de control. $\|\tilde{x}(k+j) - \tilde{x}_a\|_{\tilde{Q}}^2 = \|x(k+j) - x_a\|_Q^2 + \|u(k+j-1) - u_a\|_R^2$ porque $\tilde{Q} = \text{diag}(\text{diag}(Q), \text{diag}(R))$, N es el horizonte de predicción y $N_c \leq N$ es el horizonte de control. El concepto de horizonte de control (N_c) consiste en considerar que después de un cierto intervalo $N_c < N$, las señales de control propuestas se mantendrán constantes, es decir, $u(k+j)$ no cambia después de $j=N_c$; por lo tanto, $\Delta u(k+j)=0$ para $j > N_c-1$. El vector de variables de programación ρ_k del modelo LPV de (3.21) se predice en el horizonte N en función de las predicciones de T_e según (3.13), y b_{44} se establece en η_{bets}/E_{max} . El problema de optimización a resolver en cada paso es el siguiente:

$$V_N^*(\tilde{x}(k)) = \min_{\Delta \mathbf{u}, x_a, u_a} V_N(\tilde{x}(k), \Delta \mathbf{u}, x_a, u_a) \quad (3.26)$$

s.a

$$\tilde{x}(k+j+1) = M(\hat{\rho}_{k+j})\tilde{x}(k+j) + N(\hat{\rho}_{k+j})\Delta u(k)(k+j)$$

$$\begin{aligned}
& +N_d \left(\hat{\rho}_{k+j} \right) \hat{d}(k+j|k), \forall j \in \mathbf{z}^+_{[0, N-1]}, \\
& u_1(k+j)+u_2(k+j)+u_3(k+j)-u_4(k+j)+\hat{d}_2(k+j|k) \leq 300, \forall j \in \mathbf{z}^+_{[0, N-1]}, \\
& -(SoC_{max}-x_4(k+j))E_{max}/t_s \leq \tilde{x}_8(k+j)+\Delta u_4(k+j) \\
& \leq (\tilde{x}_4(k+j)-SoC_{min})E_{max}/t_s, \forall j \in \mathbf{z}^+_{[0, N-1]}, \\
& x^{min} \leq x(k+j+1) \leq x^{max}, \quad u^{min} \leq u(k+j) \leq u^{max}, \quad \Delta u^{min} \leq \Delta u(k+j) \leq \Delta u^{max} \quad \forall j \in \mathbf{z}^+_{[0, N-1]}, \\
& x_a(k+N) = Ax_a + B \left(\hat{\rho}_{k+N_C} \right) u_a + D \left(\hat{\rho}_{k+N_C} \right) \hat{d}(k+N_C), \\
& u^{min} \leq u_a(k+j) \leq u^{max}, \quad x_{zona}^{min} \leq x_a(k+j) \leq x_{zona}^{max}, \\
& x(k+N) = x_a
\end{aligned}$$

donde:

$$\hat{d}(k+j|k) = \left[\hat{T}_e(k+j|k), \hat{P}_{ND}(k+j|k) - \hat{P}_{PI}(k+j|k) \right]' \quad (3.27)$$

3.4.4 Resumen del esquema MPC desarrollado

El esquema completo de MPC comprende: (i) un modelo térmico simple-zona (3.1) o multi-zona (3.4), (ii) predicciones aproximadas de 24 horas utilizando modelos de predicciones simples ((3.6)), (iii) discretización y obtención del modelo discreto general en forma posicional ((3.11)) o incremental ((3.23)), (iv) formulación del problema de optimización de acuerdo con los objetivos de control deseados, (v) conversión del problema NLP con parámetros variables en el tiempo a un problema QP con parámetros fijos basada en las asunciones propuestas.

Para llegar a las formulaciones de MPC propuestas para los casos de estudio, (3.17)-(3.18) y (3.26)-(3.27), respectivamente; se aplicaron los pasos (i) a (v) mencionados anteriormente. Sin embargo, este mismo esquema también podría aplicarse a otros problemas de control, en diferentes MRs, donde los principales cambios se producirían en el paso (iv), es decir, al definir la función objetivo, las restricciones y las variables de optimización.

3.5 Aplicación y resultados de las simulaciones

3.5.1 Caso 1 de estudio: granja avícola automatizada

El caso de estudio 1 es una granja avícola que tiene un alto nivel de automatización, pero que se encuentra alejada de la red de distribución por lo que funciona en modo aislado. La nave avícola (de 70 m de largo, 30 m de ancho y 5 m de alto) cuenta con iluminación artificial y control de temperatura dentro de un rango de confort (22 - 26 °C). Se utiliza un sistema de enfriamiento con paneles evaporativos y extractores de aire para el control de la temperatura. La demanda no despachable incluye la iluminación artificial, los equipos asociados al sistema de automatización (como bombas de agua, cintas transportadoras, etc.) y las actividades realizadas por el personal durante el día. Por otro lado, el equipo de climatización se considera como una demanda despachable o controlable, considerando su potencia (kW) como una variable continua [94]. Los parámetros del modelo térmico se calcularon teniendo en cuenta las dimensiones del galpón y sus características de construcción (como los materiales utilizados en las paredes, pisos y techo [103], [104]) y dieron como resultado los siguientes valores: $R=1,13$ °C/kW, $C=3,5$ kWh/°C. La MR incluye 15 kW de paneles fotovoltaicos, un generador diésel de 10 kW y baterías con capacidad total de 5 kWh (con un SoC mínimo permitido de 0,2). La potencia máxima del sistema de climatización es de 10 kW. Dado que el seguimiento de T_i en la zona no es una cuestión sustancial para esta aplicación, al igual que el seguimiento del punto de ajuste del SoC , se establecieron los siguientes pesos: $Q=diag(3,5)$, $R=diag(1,1,1)$, ajustados por simulación, considerando una desviación térmica y un esfuerzo de control aceptable. El horizonte elegido es de 24 horas ($N = 48$ para un tiempo de muestreo de 0,5 horas).

Las Figura 3.5 y Figura 3.6 muestran el rendimiento a lazo cerrado del controlador MPC propuesto para algunos días de enero. En particular, la Figura 3.5 muestra la evolución temporal de las dos variables controladas (T_i y SoC) en comparación con la temperatura externa (T_e) y la potencia disponible de los paneles fotovoltaicos (P_{PV}), respectivamente. La Figura 3.6 muestra la evolución temporal de las variables manipuladas (puntos de ajuste del subsistema: P_{PV} , P_G , P_D), la potencia de la batería (P_B) y el consumo de carga no despachable (P_{ND}). En la parte superior de la Figura 3.5, se observa cuando la estrategia predice una gran demanda futura, lo que obliga a T_i a acercarse a su límite inferior de confort (22 °C) para poder satisfacer esa demanda cuando sea necesario; es decir, se observa que el MPC aumenta la refrigeración (mínimos locales de T_i) cuando pronostica un aumento en T_e (máximos locales de T_e) y en la generación fotovoltaica disponible (máximos locales de P_{aPV}) en el horizonte. Luego, a medida que el MPC predice que la refrigeración lograda en la granja avícola es suficiente durante un tiempo (debido a su inercia térmica), la demanda de energía del equipo de aire acondicionado

P_D disminuye para priorizar la carga de las baterías (P_B). Mientras tanto, en la parte inferior de la Figura 3.5, se puede apreciar que las baterías se cargan durante el día (cuando la generación fotovoltaica es alta) y se descargan durante la noche, para aprovechar mejor la energía solar. Se observa que en los días soleados se reduce significativamente el uso del generador diésel (P_G). Cuando la generación solar no es suficiente para abastecer P_{ND} y P_D , se utiliza primero la energía de las baterías P_B y luego se pone en marcha el generador diésel (P_G). Durante el funcionamiento de refrigeración, T_i se mantiene cerca del límite superior (26 °C), perdiendo confort térmico pero reduciendo el consumo de energía.

El rendimiento de la estrategia de gestión se cuantifica mediante seis indicadores de rendimiento que evalúan el uso de la energía generada por los paneles, el uso de las baterías y el generador diésel, además del confort térmico logrado. Estos indicadores son los siguientes: I₁: Porcentaje de energía solar utilizada en comparación con la energía solar disponible; I₂: porcentaje de la demanda de energía suministrada por los paneles fotovoltaicos; I₃: porcentaje de la demanda de energía suministrada por la batería; I₄: porcentaje de la demanda de energía suministrada por el generador diésel; I₅: *SoC* promedio que indica la proporción entre carga y descarga; e I₆: temperatura interna promedio junto con el rango de valores. La Tabla 3.1 muestra el rendimiento de la estrategia de gestión energética propuesta para el estudio de caso durante el mes de enero. Para este mes en particular, el consumo total de energía fue de 4556 kWh, donde 1818 kWh (40%) correspondieron al consumo del equipo de climatización. En particular, las cargas consumieron 2431 kWh ($I_2=100 \cdot 2431 / 4556=53\%$) de los paneles fotovoltaicos, 705 kWh ($I_3=100 \cdot 705 / 4556=16\%$) de las baterías y 1420 kWh ($I_4=1420 / 4556=31\%$) del generador diésel. De la energía solar generada, se utilizaron 746 kWh (23%) para cargar las baterías. En resumen, los resultados de la simulación sugieren que el uso de la energía solar fue muy bueno, cerca del 92% ($I_1=100 \cdot 3177 / 3452=92\%$), suministrando prácticamente el 69% ($I_2+I_3=69\%$) del consumo total, mientras que el 31% restante fue suministrado por el generador diésel. El *SoC* promedio fue del 52% (es decir, $I_5=52\%$), lo que indica un buen equilibrio entre carga y descarga. En cuanto al confort térmico, debido a que el control de zona funciona entre 22 °C y 26 °C, la temperatura interna se mantuvo alrededor de 24,2 °C con un rango de valores igual a 4 °C (es decir, $I_6: T_{i,prom}=24,2$ °C, *rango*=4 °C). Para esta MR aislada de la red de distribución, el uso de energía renovable demostró ser alto, pero si se aumentara la capacidad de la batería, su factor de uso podría ser inclusive mayor. Sin embargo, esto implica mayores costos de inversión y mantenimiento.

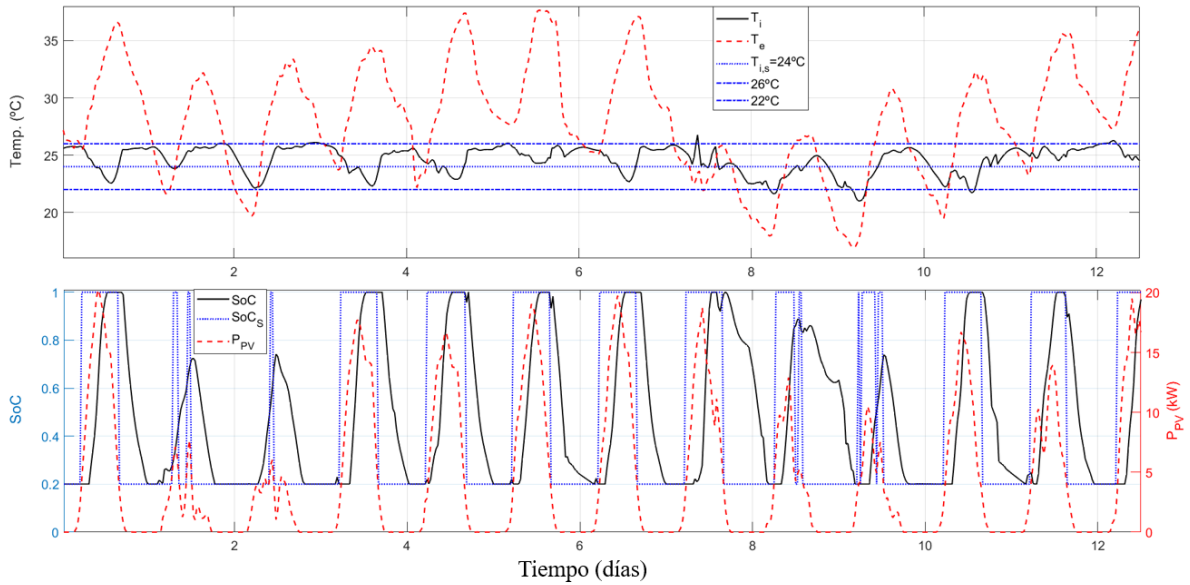


Figura 3.5. Evolución temporal de las variables controladas T_i y SoC respecto a sus setpoints ($T_{i,s}$ y SoC_s), comparados con la temperatura externa T_e y la generación fotovoltaica P_{PV} , respectivamente.

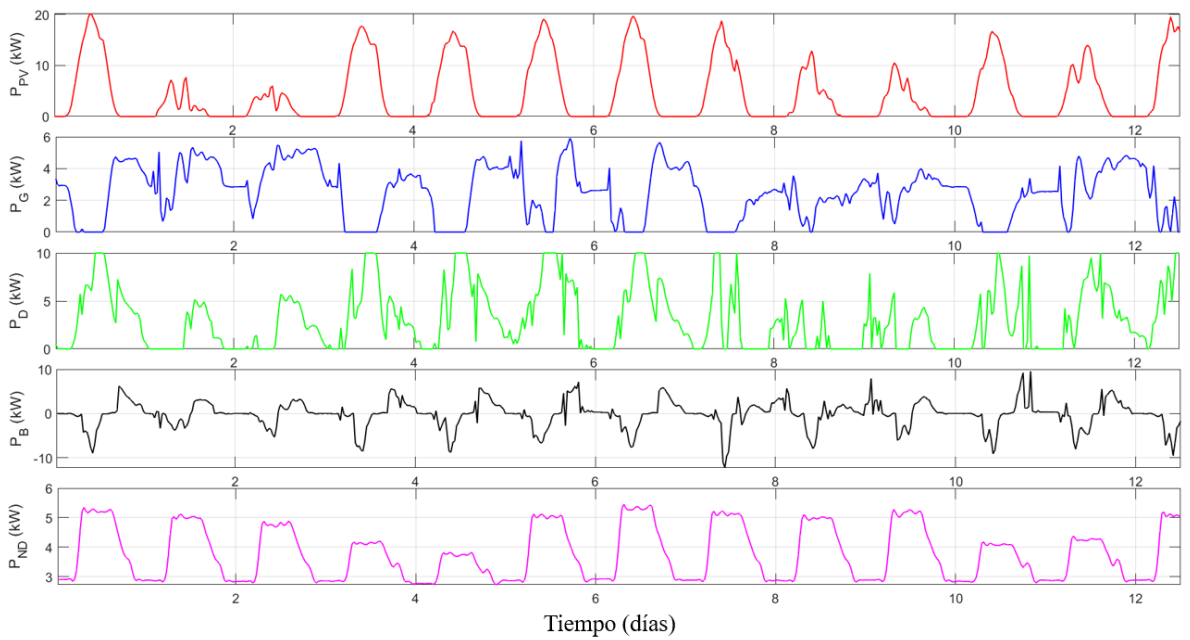


Figura 3.6. Flujo de potencia en el bus del sistema (generación y demanda). Evolución temporal de las variables manipuladas (P_{PV} , P_G , P_D), de la potencia del banco de baterías (P_B) y de la demanda de la carga no despachable (P_{ND}).

La estrategia de gestión predictiva también se evaluó teniendo en cuenta las distorsiones en los modelos de pronóstico de las perturbaciones (generación fotovoltaica disponible, carga no despachable y temperatura externa). Se aplicaron distorsiones de $\pm 50\%$ a los modelos escalando los perfiles promedio diarios por factores de 0,5 (es decir, -50%) o 1,5 (es decir, $+50\%$). La Tabla 3.1 muestra el rendimiento del control propuesto sin distorsión en los modelos

de predicción y también con distorsiones aplicadas a los tres modelos de predicción, primero para -50% y luego para +50%. Al comparar estos escenarios de control en la Tabla 3.1, se puede ver que no hay variaciones significativas en el rendimiento cuando se aplican distorsiones a los modelos de pronóstico, lo que confirma que este controlador basado en MPC tolera grandes desajustes entre el modelo y la planta.

Control basado en MPC										
Dist. (%)	Generación (kWh)				Almacenamiento en baterías		Consumo (kWh)		Confort térmico (°C)	
	Gen.	PV (disp.)	PV (usado)		Descarga (kWh)	SoC _{prom} (%)	Tot.	HVAC	T _{i, prom}	Rango
			Carga	Carga de bat.						
0	1420	3452	2431	746	705	52	4556	1818	24.2	4
-50	1445		2376	737	687	54	4508	1770	24.2	4
+50	1429		2443	768	742	54	4614	1876	24.2	4.2
Control basado en reglas										
-	2198	3452	2099	644	598	41	4895	2160	24	4.2

Tabla 3.1. Desempeño a lazo cerrado de cuatro escenarios de control simulados para el mes de enero.

Para comparar la estrategia de gestión predictiva con una más simple, se desarrolló un control basado en reglas de encendido y apagado con histéresis para controlar T_i y SoC mediante la activación/desactivación del equipo de climatización y la carga/descarga de las baterías, respectivamente. Se asume que el equipo de aire acondicionado es de frío-calor y que su funcionamiento se configura automáticamente para refrigeración o calefacción, según sea necesario. Cuando el equipo de aire acondicionado está en funcionamiento, su demanda de energía es igual a su potencia nominal ($P_D = 10$ kW). Este controlador de encendido y apagado con histéresis intenta mantener la temperatura dentro del mismo rango de confort térmico. La estrategia utilizada para controlar el SoC con histéresis es *Load Following* (LF en HOMER Pro®), en la que la carga de las baterías solo se realiza con energía de los paneles fotovoltaicos. Una vez que se ha alcanzado el máximo SoC (es decir, se completa la carga), el punto de ajuste del inversor se controla para igualar la generación con la demanda. El generador diésel se pone en marcha únicamente cuando la demanda de la carga no puede ser abastecida a través de los paneles y de las baterías. En este caso, las baterías se desconectan y se utiliza toda la generación solar disponible y el déficit de energía se suministra mediante el generador diésel.

La Tabla 3.1 también compara el rendimiento de la gestión realizada con el control basado en MPC propuesto y el control basado en reglas. Ambos controladores permiten que las baterías se carguen solo a través de los paneles solares. Para el control basado en reglas, el consumo

total de energía fue de 4895 kWh, donde 2160 kWh (44%) corresponden al consumo del equipo de climatización. El suministro de energía se realizó de la siguiente manera: 2099 kWh ($I_2=43\%$) de los paneles fotovoltaicos, 598 kWh ($I_3=12\%$) de las baterías (por lo tanto, $I_2+I_3=55\%$) y 2198 kWh ($I_4=45\%$) del generador diésel. El uso de la energía solar disponible fue $I_1=79\%$. En particular, la alta contribución de energía del generador diésel se debe al aumento en el consumo del equipo de climatización y la disminución en el uso de la energía solar disponible. En comparación con la estrategia basada en MPC, el controlador basado en reglas requirió 342 kWh más de energía (un 19% más) para controlar el equipo de climatización, para lo cual se generaron 778 kWh adicionales (un 55% más) a partir del generador diésel y se desperdicia el 434 kWh de energía solar. También se observa que la gestión de la batería es peor, con $I_5=SoC_{prom}=41\%$, ya que las baterías se descargan más de lo que se cargan, lo que indica un uso deficiente. En resumen, el control basado en reglas produce un peor rendimiento en la gestión de energía para un confort térmico similar ($I_6: T_{i, prom}=24\text{ °C}$, $rango=4.2\text{ °C}$).

3.5.2 Caso 2 de estudio: centro de salud

El caso de estudio es el propuesto en la Sección 2.4, cuya demanda esporádicamente supera la demanda máxima permitida por la tarifa de 300 kW, como puede observarse en la Figura 2.6. Para evitar que los picos superen los 300 kW y que se aplique la tarifa de energía más costosa, se propone la instalación de paneles fotovoltaicos que generan energía cuando la demanda del centro es mayor (particularmente la demanda de los equipos de climatización), además de tener bajo costo de mantenimiento, disminuyendo la cantidad de baterías necesarias.

En este caso, se supone que el CS se divide en 3 zonas grandes con equipos de aire acondicionado independientes, como se muestra en la Figura 3.4 y que además los equipos de aire acondicionado son tipo *inverter*, considerando su potencia como una variable continua. La distribución de las unidades de aire acondicionado es la siguiente: la zona 1 tiene 17 unidades (potencia máxima igual a 100 kW), la zona 2 tiene 11 unidades (potencia máxima igual a 65 kW) y la zona 3 tiene 10 unidades (potencia máxima igual a 59 kW). Para determinar los parámetros R y C , se considera la construcción de las paredes con ladrillos cerámicos y aislamiento térmico, considerando las áreas de las ventanas de cada zona. La Figura 3.4 distingue entre las zonas 1 y 3, donde se encuentran las oficinas, salas de examen y salas de procedimientos para tratamiento junto a las de diagnóstico. Estas últimas, tienen compartimentos más pequeños que la zona 2, donde se encuentra la entrada, la recepción y un

lugar para recreación, y que tiene más circulación y espacios abiertos. Esta diferenciación responde al hecho de que los parámetros R y C dependen de los flujos de calor entre las salas y el exterior. En este sentido, se determinaron los siguientes parámetros: $R_1 = 0.22$, $C_1 = 1.3$, $R_{12} = 46.8$, $R_2 = 0.2$, $C_2 = 0.91$, $R_3 = 0.32$, $C_3 = 0.81$ y $R_{23} = 46.8$. Por otro lado, la MR propuesta se compone por un banco de baterías con capacidad de 15 kWh y 20 kW de paneles fotovoltaicos. El intervalo de acción del controlador es de 15 minutos (o 0.25 horas), igual al intervalo de medición utilizado por la distribuidora de energía. Para este sistema, el controlador basado en MPC propuesto (de la ecuación (3.26)) se configuró con los siguientes parámetros: $Q = \text{diag}(90, 15, 90, 500)$, $R = \text{diag}(0.01, 0.01, 0.01, 1)$, $S = \text{diag}(5, 5, 5, 0.005)$, $N = 24$ (6 [h]) y $N_c = 8$ (2 [h]). El intervalo de confort térmico es de 23 a 25 °C, y el punto de operación deseado dentro del intervalo es de 24 °C. Luego, $x'_s = [24, 24, 24, 1]$ y $[23, 23, 23, 0.98] \leq x'_a \leq [25, 25, 25, 1]$. Los perfiles de demanda de potencia promedio mostrados en la Figura 2.7 se utilizaron para predecir la demanda no despachable en cada mes del año.

La Figura 3.7 muestra el desempeño del controlador propuesto, durante algunos días de enero y, en particular, la evolución temporal de las variables controladas (T_1 , T_2 , T_3 , SoC), las variables manipuladas (P_1 , P_2 , P_3 , P_B) y una de las perturbaciones medidas (T_e). El gráfico superior de la Figura 3.7 muestra las tres temperaturas internas (T_1 , T_2 , T_3) y la temperatura externa T_e . El gráfico intermedio de la Figura 3.7 muestra el SoC de las baterías. El gráfico inferior de la Figura 3.7 muestra las potencias P_1 , P_2 , P_3 demandadas por los equipos de aire acondicionado en cada zona (es decir, las cargas controlables) y la potencia del banco de baterías P_B . La zona 2 tiene menor prioridad porque es una zona de circulación, por lo tanto, los requisitos de confort térmico para T_2 son menos estrictos (es decir, T_2 puede violar momentáneamente el intervalo de temperatura deseado cuando sea necesario). La mayor parte del tiempo, las temperaturas internas se mantienen dentro del rango de temperatura deseado (23 - 25 °C) y, solo durante unas pocas horas, T_2 se desvía del rango cuando el SoC disminuye. Estas descargas del banco de baterías (es decir, cuando $P_B > 0$ y $SoC < 1$) proporcionan la energía necesaria para mantener la demanda de la red principal (P_{MG}) por debajo de los 300 kW, manteniendo el confort térmico dentro de los valores admisibles. Los perfiles de demanda de potencia de P_1 , P_2 y P_3 tienen formas similares, que son consistentes con T_e . La Figura 3.8 también muestra el desempeño en bucle cerrado, en particular, las variables involucradas en el balance generación-consumo dado por: $P_{MG} + P_{PV} + P_B = L_T$, donde la carga total L_T es la suma de los cuatro consumos, es decir, $L_T = P_{ND} + P_1 + P_2 + P_3$. Estas variables se muestran en relación con la demanda máxima de potencia permitida (o umbral, Th). Se observa que la variable

controlada T_2 (temperatura interna en la zona 2) es la que más se aleja del intervalo de confort cuando la demanda no despachable P_{ND} y la temperatura externa T_e son elevadas (ver Figura 3.7 y Figura 3.8). Por lo tanto, es necesario reducir la demanda de las cargas no controlables (en este caso, principalmente se reduce P_2) para cumplir con el equilibrio y la limitación de 300 kW. En estos eventos, el pico de P_2 se desplaza con respecto al pico de P_1 y P_3 (es decir, cambio de carga), y la demanda de potencia de la sala 2 (P_2) disminuye significativamente (forma de carga flexible), causando una mayor desviación de T_2 con respecto al intervalo de confort. Esta jerarquía de control inferior de la sala 2 con respecto a las otras zonas se logra simplemente estableciendo un peso más bajo asociado a la variable controlada correspondiente, en este caso, en $Q(2,2)$. Por otro lado, el alto valor de $R(4,4)$, en comparación con los otros pesos en R , provoca una minimización de la magnitud de P_B , mientras que el bajo valor del factor de supresión del movimiento $S(4,4)$ da lugar a una maximización del incremento ΔP_B (es decir, se permite que ΔP_B varíe más que los demás incrementos). El equilibrio entre la energía entregada y la desviación permitida de las temperaturas internas está determinado por los coeficientes de la función de costo. Este comportamiento en lazo cerrado influenciado por los valores establecidos en Q , R y S se verifica en las Figura 3.7 y Figura 3.8.




Figura 3.7. Desempeño a lazo cerrado del controlador propuesto. Evolución temporal de las variables controladas (T_1 , T_2 , T_3 , SoC), de las variables manipuladas (P_1 , P_2 , P_3 , P_B), y una de las perturbaciones medidas (T_e).




Figura 3.8. Desempeño a lazo cerrado del controlador propuesto. Evolución temporal de las variables involucradas en el balance generación-consumo (L_T , P_{MG} , P_B , P_{PV} , P_{ND}) en relación con la demanda de potencia pico (Th) permitida por la tarifa contratada.

En el año 2021, la factura mensual promedio de electricidad del centro médico era de \$853920, mientras que, si se aplica la estrategia de gestión de energía propuesta, la factura podría reducirse a \$633550. Por lo tanto, el ahorro mensual sería de \$220370 (aproximadamente el 26%), que se deben principalmente a que no se supera la demanda máxima de potencia permitida de 300 kW. Debido al esquema tarifario, si la demanda máxima de potencia registrada supera el máximo permitido, la demanda máxima de potencia contratada se actualiza automáticamente a la registrada para los próximos cuatro meses, y, por lo tanto, también el precio de la energía (es decir, el precio de la energía aplicado durante este período corresponderá a una demanda de potencia superior a 300 kW). De esta manera, suponiendo el mismo perfil de demanda de potencia durante los cuatro meses, se puede estimar un ahorro cuatrimestral de \$881480, y suponiendo que cada cuatro meses hay una demanda máxima de potencia superior a 300 kW, el ahorro anual estimado sería de \$2644440. En consecuencia, con una inversión muy pequeña, principalmente en baterías, se pueden lograr grandes ahorros sin perder el confort térmico. Además, la tecnología necesaria para implementar la estrategia de gestión de energía propuesta requiere solo 15 baterías con una capacidad de 1 kWh cada una y 20 kW de paneles fotovoltaicos. Además, los consumidores cuya demanda de potencia de la red principal supere los 300 kW deberán consumir el 20% de su energía de generación renovable en el año 2025. Para cumplir con este requisito legal, el centro tendría que instalar 150 kW de paneles fotovoltaicos, lo que representa una inversión mucho más alta (750% más alta) que la necesaria para la aplicación de la estrategia de gestión propuesta. Este valor de

potencia se obtuvo a través de HOMER Pro®. Se utilizaron datos de radiación solar de la región y el perfil de demanda anual de la instalación de salud. La gestión de energía se configuró como *Load Following* y la simulación se configuró de modo que los paneles fotovoltaicos proporcionaran el 20% del consumo de energía de la instalación de salud.

3.6 Discusión

En este capítulo se presentó un esquema completo y fácilmente ajustable de MPC para la gestión conjunta del despacho de la generación y de la respuesta a la demanda en microrredes aisladas o conectadas a la red de distribución, que utilizan sistemas de climatización. Esta estrategia de control permite el uso eficiente de diferentes recursos de energía al tiempo que se mantiene el confort térmico, basándose en la predicción futura de perturbaciones para controlar las cargas despachables, los dispositivos de almacenamiento y los dispositivos de generación. A través de las perturbaciones y las predicciones del sistema, el control predictivo toma acciones de control, de forma anticipada, sobre el banco de baterías y los equipos de HVAC.

Las estrategias de respuesta a la demanda aplicadas (tanto implícita como explícitamente) por el control son: conservación estratégica y desplazamiento de carga (Figura 2.1). Estos servicios permiten mantener el confort térmico y el equilibrio entre generación y demanda (para MRs aisladas), además de limitar la solicitud de potencia a la red de distribución (para MRs con conexión a red). Se desarrollaron formulaciones de MPC para el control directo de los flujos de potencia, resultando en optimizaciones viables para sistemas embebidos.

Se presentaron dos microrredes de estudio de interés regional con resultados prometedores. El primero (asociado a la industria avícola, operando en modo aislado) indica que el esquema de MPC diseñado, en comparación con un control basado en reglas con histéresis, aprovecha mejor la generación fotovoltaica a través de la gestión predictiva de las baterías y del sistema de HVAC, reduciendo así el uso del generador diésel y, en consecuencia, disminuyendo los costos de combustible. El segundo caso (un caso típico de un usuario con elevada demanda, conectado a la red, con demandas de potencia máxima cercanas a la demanda máxima permitida) sugiere que, con una inversión inicial muy baja en baterías y paneles fotovoltaicos, es posible reducir la demanda máxima de potencia de la red, lo que proporciona ahorros significativos. Las comparaciones indican que la gestión de energía propuesta optimiza el rendimiento de ambas microrredes y proporciona beneficios económicos.

Capítulo 4:

SISTEMA DE PROTECCIÓN PARA MICRORREDES DC

4.1 Resumen del capítulo

La necesidad de abastecer el rápido aumento del consumo mundial de energía a través de generación limpia y sostenible ha impulsado el desarrollo de microrredes como parte fundamental del paradigma de las REI y la GD. La operación de MRs implica una serie de desafíos asociados a la gestión de la energía, que fueron discutidos en los Capítulos 2 y 3, pero también asociados a los sistemas de protección, necesarios para garantizar un funcionamiento seguro y estable. La variabilidad de los recursos renovables y la baja inercia de los convertidores electrónicos generan corrientes de falla variables en las MRs durante eventos de fallas, especialmente al operar en modo aislado. Por esta razón, los sistemas de protección tradicionales basados en niveles de corriente definidos pueden ser ineficientes. En este capítulo, se propone un método de supervisión de fallas basado en comunicación y en modelo, que provee resiliencia a microrredes DC que incluyen generación renovable y dispositivos de almacenamiento frente a fallas de cortocircuito o circuito abierto. El método proporciona una capa adicional de seguridad respecto a las protecciones tradicionales, incluida la de los convertidores electrónicos, a través de la detección, identificación, localización y aislación de fallas en MRs DC. El método requiere conocer las tensiones y corrientes en cada carga y en cada convertidor electrónico de la microrred, utilizando la capacidad de comunicación que estos últimos poseen para enviar estos datos a una central de cómputo. La central resuelve un problema de optimización que incluye el modelo de las líneas de la MR y detecta si se produjo una falla, identifica de qué tipo es y dónde sucedió. La aislación de la falla se produce a partir de que la central envía una señal de apertura a los *circuits breakers* y/o convertidores electrónicos que la contenga. Esta señal se envía por las líneas y buses de la MRs, utilizándolos como canal de comunicación, a través de modulación armónica. El esquema se aplica a un modelo de simulación de falla de una microrred aislada que incluye paneles fotovoltaicos y baterías. Se realizan simulaciones en diferentes escenarios, que tienen diferentes niveles de radiación solar y estados de carga de las baterías, además de fallas de distintos tipos y en distintas ubicaciones. En particular, para escenarios de falla con baja radiación solar y baja carga de batería, las protecciones del convertidor no funcionan debido a las bajas corrientes de falla. Sin embargo, el esquema de protección permitió detectar, localizar y finalmente aislar la

falla mediante los *circuits breakers* correspondientes, permitiendo que la carga siga siendo alimentada.

4.2 Introducción

Los sistemas de protección de las MRs deben asegurar que su operación sea confiable y segura durante funcionamiento en modo aislado y con conexión a red [105]. El principal inconveniente es la naturaleza intermitente de los recursos renovables que resultan en corrientes de fallas variables [106], la bidireccionalidad de los flujos de potencia (que en los sistemas de energía tradicionales son unidireccionales) y la utilización de convertidores electrónicos [107]. Las protecciones necesarias para operación en modo aislado son más complejas respecto al funcionamiento conectado a red debido a los bajos niveles de corrientes de cortocircuito y a la diversidad de topologías posibles [108].

La detección e identificación de fallas en MRs eléctricas consiste en ubicar la falla lo suficientemente rápido para poner en acción un sistema de protección o una reconfiguración de la MR. Trabajos actuales abordan esta temática con un amplio rango de metodologías [28], que en general pueden clasificarse en métodos basados en modelo (*model-based method*) y métodos basados en datos (*data-driven method*) [109]. Los primeros, utilizan modelos físicos verificados para representar el sistema durante el funcionamiento normal y durante las fallas. Usualmente se componen de dos etapas: 1) generación residual, donde se calcula la diferencia (residuo) entre mediciones reales y valores estimados por modelo (diferencia planta-modelo); y 2) evaluación residual, donde se analiza el residuo obtenido para detectar o identificar una falla. Por otro lado, los métodos puramente impulsados por datos utilizan información obtenida mediante medición o simulación del sistema para entrenar algoritmos, por lo que requieren mucha información y tiempos de muestreo lo suficientemente elevados para poder extraer las características o *features* de las señales [110].

Muchos trabajos proponen estrategias adaptativas frente a la incertidumbre de la generación renovable [111], como en [112], donde se utilizan relés de sobre-corriente adaptativos con una estrategia diferencial sencilla para detectar y aislar fallas. Los relés se instalan al final de cada línea y miden la corriente a través de transformadores de corriente. En caso que la diferencia entre las corrientes sea mayor a un umbral, se detecta la falla y se aísla el tramo afectado. El umbral se modifica según la MR esté o no conectada a la red. Es efectivo y escalable, pero requiere de gran cantidad de relés con capacidad de comunicación entre ellos. Otros métodos detectan fallas utilizando procesamiento de señales, evitando la necesidad de comunicación. Por

ejemplo, los autores de [113], utilizan minería de datos y la transformada ondita multi-resolución para detectar, identificar y clasificar fallas. De manera similar, en [114], se utiliza minería de datos, pero en conjunto con paquetes de onditas para extraer *features* de las señales de tensión y corriente, pudiendo en ambos casos detectar fallas simultaneas. Por otro lado, se observa una tendencia reciente en la utilización de técnicas de aprendizaje maquina para el desarrollo de métodos basados en modelos. En este sentido, los autores de [115] proponen un método basado en una máquina de soporte vectorial para detectar fallas en una MR DC. La ventaja de estos métodos es que requieren de una única medición, pero necesitan una frecuencia de muestreo elevada de las señales de falla y de una gran cantidad de datos precisos para la etapa de entrenamiento, difícil de obtener mediante simulación. En [31] se propone un esquema para MRs aisladas basadas en convertidores electrónicos, donde la comunicación entre los componentes de la MR se lleva a cabo mediante señales inyectadas en las propias líneas de alimentación, similar a la operación de la tecnología PLC (*Power-Line Communication*). Los convertidores detectan fallas de manera individual e inyectan señales armónicas a la red para indicar a los relés de protección la ubicación de la falla de modo de poder aislarla. Las fallas son detectadas por los terminales de los convertidores a través del análisis de las secuencias positivas y negativas de la tensión. El esquema es práctico porque no requiere comunicación adicional y porque es escalable, pero no es robusto debido a que falla en determinados escenarios.

En general, en la literatura se encuentran soluciones complejas, poco robustas o muy redundantes en cuanto a la necesidad de comunicación. Los métodos sin comunicación, como los basados en aprendizaje supervisado (redes neuronales o máquina de soporte vectorial) o transformada ondita, son soluciones particulares que dependen de la topología de cada MR. Además, requieren de mucha información precisa para entrenar modelos u obtener *features* de modo de lograr resultados satisfactorios. En este sentido, los trabajos encontrados hacen uso de simplificaciones teóricas que difieren de la realidad. Una de la más difundida es la suposición de que los inversores entregan el doble de potencia durante un cortocircuito cuando en realidad la señal transitoria de la falla depende del diseño del convertidor electrónico, principalmente del filtro de salida, y de su modo de funcionamiento frente a fallas [116]. Por otro lado, los convertidores electrónicos poseen módulos de comunicación, por lo que hoy en día es posible desarrollar soluciones basadas en la comunicación que sean aplicables desde un punto de vista práctico y económico. La utilización de comunicación implica un desempeño mucho más robusto, sin embargo, los métodos encontrados en la literatura requieren excesiva cantidad de nodos de comunicación (equipos y relés), siendo poco prácticos y aplicables.

En este capítulo se propone un método sencillo y eficaz de protección para MRs DC, frente a fallas de cortocircuito y circuito abierto, que adiciona una capa de protección a las tradicionales de corriente incluidas en convertidores. El método utiliza un algoritmo sencillo basado en un principio de optimización y en la comunicación de los convertidores electrónicos y las cargas con una central de cómputo. La detección de las fallas en las líneas de la MR requiere de la medición de corriente y tensión, además de modelos de impedancia de las líneas. La detección se lleva a cabo a través de la comparación de variables medidas en distintos puntos de la MR con variables predichas a través de modelos. El esquema se aplica al lado DC de una microrred similar al Caso 1 de estudio del Capítulo 3, compuesta por generación fotovoltaica, baterías, cargas AC y los respectivos convertidores electrónicos asociados. Las simulaciones realizadas arrojaron buenos resultados.

4.3 Método propuesto

Se propone un método de protección de una capa superior a la de los sistemas de protección tradicionales capaz de detectar, identificar, localizar y aislar fallas. Su objetivo es mejorar la estabilidad, confiabilidad y resiliencia de la MR a través de la aislación de fallas, lo que permite continuar con el funcionamiento de la MR aún bajo situaciones de falla.

Para su funcionamiento, el método se basa en modelos de fallas para líneas de MRs (descritos mediante ecuaciones de mallas y de nodos) y en la capacidad de comunicación de los convertidores y las cargas. Se asume que, tanto los convertidores electrónicos como los generadores y las cargas poseen capacidad de comunicación para enviar sus valores instantáneos de corriente y tensión a una central de cómputo que ejecuta el algoritmo. Actualmente, los convertidores incorporan tecnología de comunicación, por lo que sólo se debe adicionar módulos de comunicación y de medición en los puntos de conexión de las cargas eléctricas. Para el modelo de fallas, se requiere únicamente el valor resistivo de las líneas, fácilmente calculable. Además, el método tiene bajo costo computacional dado que se basa en la resolución de ecuaciones algebraicas, facilitando su implementación en cualquier hardware.

Su funcionamiento es secuencial y se constituye por las siguientes etapas: 1) detección, 2) identificación, 3) localización y 4) aislación de la falla. Los criterios de detección de falla de cortocircuito o circuito abierto utilizan valores umbrales de corriente y de tensión, respectivamente, que permiten identificar la falla para luego ser localizada a través de la reconciliación de las mediciones con el modelo de la MR.

4.3.1 Asunciones

Para el desarrollo del método, se realizaron asunciones que simplifican tanto los modelos de falla como los cálculos necesarios, pero manteniendo la validez del método. Estas asunciones son las siguientes:

Asunción 1: los convertidores y las cargas tienen módulos de medición y de comunicación. En la actualidad, los convertidores electrónicos tienen módulos de comunicación con distintas tecnologías y protocolos. Por otro lado, se requiere anexar a las cargas módulos de medición de corriente y tensión, además de módulos de comunicación. Las mediciones de corriente y tensión instantáneas deben enviarse a una central de cómputo (CPU, *Central Processing Unit*), encargada de ejecutar el algoritmo.

Asunción 2: solo se produce una falla a la vez. Esta asunción es válida en la mayoría de los casos dado que rara vez se producen fallas simultáneas en una microrred.

Asunción 3: las impedancias de línea son puramente resistivas. Esta consideración es válida dado que el método se aplica a MRs de continua, por lo que los efectos resistivos predominan ampliamente por sobre los reactivos.

Asunción 4: los circuitos breaker constan de filtros pasa-banda. Se supone que cada CB consta de un filtro sintonizado a una frecuencia específica de manera de poder detectar la señal armónica inyectada en el bus DC, según la ubicación de la falla determinada por la CPU.

4.3.2 Modelado de fallas en líneas

En este apartado, se desarrollan modelos básicos de fallas de cortocircuito (*short circuit*, SC) y circuito abierto (*open circuit*, OC) para líneas de alimentación, que pueden ser aplicados a MRs complejas y extensas.

Sobre la base de la *asunción 3* del apartado 4.3.1, estos modelos sólo requieren conocer como único parámetro a la resistencia eléctrica, la cual puede calcularse fácilmente en base a la resistividad del conductor y a su longitud. Además, utilizan asunciones para simplificar los cálculos y disminuir la cantidad de variables del problema.

A. Falla de cortocircuito

El modelo para fallas de cortocircuito se muestra en la Figura 4.1. Se observa que, al producirse un cortocircuito en una línea, la misma se divide en dos tramos a partir de la aparición de una resistencia de falla (R_f) que produce una corriente de falla (i_f).




Figura 4.1. Modelo para fallas de cortocircuito.

Como la línea es puramente resistiva (*asunción 3* del apartado 4.3.1) la suma del valor de cada tramo (R_o' y R_o'') es igual a la resistencia total de la línea (R_o), la cual puede determinarse fácilmente a través de su resistividad y longitud:

$$R_o = R_o' + R_o'' \quad (4.1)$$

Por lo tanto, los valores de R_o' y R_o'' están determinados por el valor total R_o y por la ubicación de la falla sobre la línea.

Planteando las ecuaciones de malla y nodo del circuito de la Figura 4.1, se obtiene (4.2) y (4.3), respectivamente.

$$v_i - i \cdot R_o' - \hat{i} \cdot R_o'' - v_o = 0 \quad (4.2)$$

$$i - \hat{i} - i_f = 0 \quad (4.3)$$

La ubicación exacta del cortocircuito en la línea no es información relevante en MRs, ya que solo se necesita identificar qué línea contiene la falla para poder aislarla. En este sentido, es posible introducir en el modelo una *asunción* adicional que considera la ubicación de la falla en la mitad de la línea, es decir $R_o' = R_o'' = \frac{R_o}{2}$. Si bien esta *asunción* puede producir un error en la localización de la falla (que aumenta conforme la falla se aleja del centro de la línea), permite disminuir la cantidad de variables del problema y localizar con éxito la falla en la mayoría de los casos. Teniendo en cuenta esto, e introduciendo (4.3) en (4.2):

$$v_o = v_i - i \cdot R_o + i_f \cdot \frac{R_o}{2} \quad (4.4)$$

La ecuación (4.4) muestra que, si no existe falla, es decir $i_f=0$, la tensión de salida es igual a la de entrada menos la caída de tensión en la línea. Por otro lado, si existe una falla, se adiciona un término de tensión.

B. Falla de circuito abierto

El modelo de fallas de circuito abierto se muestra en la Figura 4.2. El mismo se basa en la incorporación de una fuente de tensión virtual V_d que representa la diferencia de potencial entre los extremos de la línea cuando se abre el circuito.




Figura 4.2. Modelo para fallas de circuito abierto.

La ecuación del modelo se expresa en (4.5).

$$v_i - i \cdot R_o - v_d - v_o = 0 \quad (4.5)$$

De esta manera, si la línea funciona normalmente, $v_d=0$; pero si la línea se abre, la corriente se hace cero y v_d se hace igual a la diferencia de potencial entre los extremos de la línea.

4.3.3 Aplicación de los modelos básicos de fallas a una microrred

Se propone la aplicación de los modelos de fallas propuestos en una MR genérica de estudio, cuyo diagrama unifilar se expone en la Figura 4.3. Se observan los sentidos de circulación propuestos para las corrientes y la ubicación de los interruptores de protección de corriente continua (SSCB, *solid state circuit breaker*). Los modelos de fallas expuestos en el apartado 4.3.2 se aplican a cada una de las líneas de la MR.

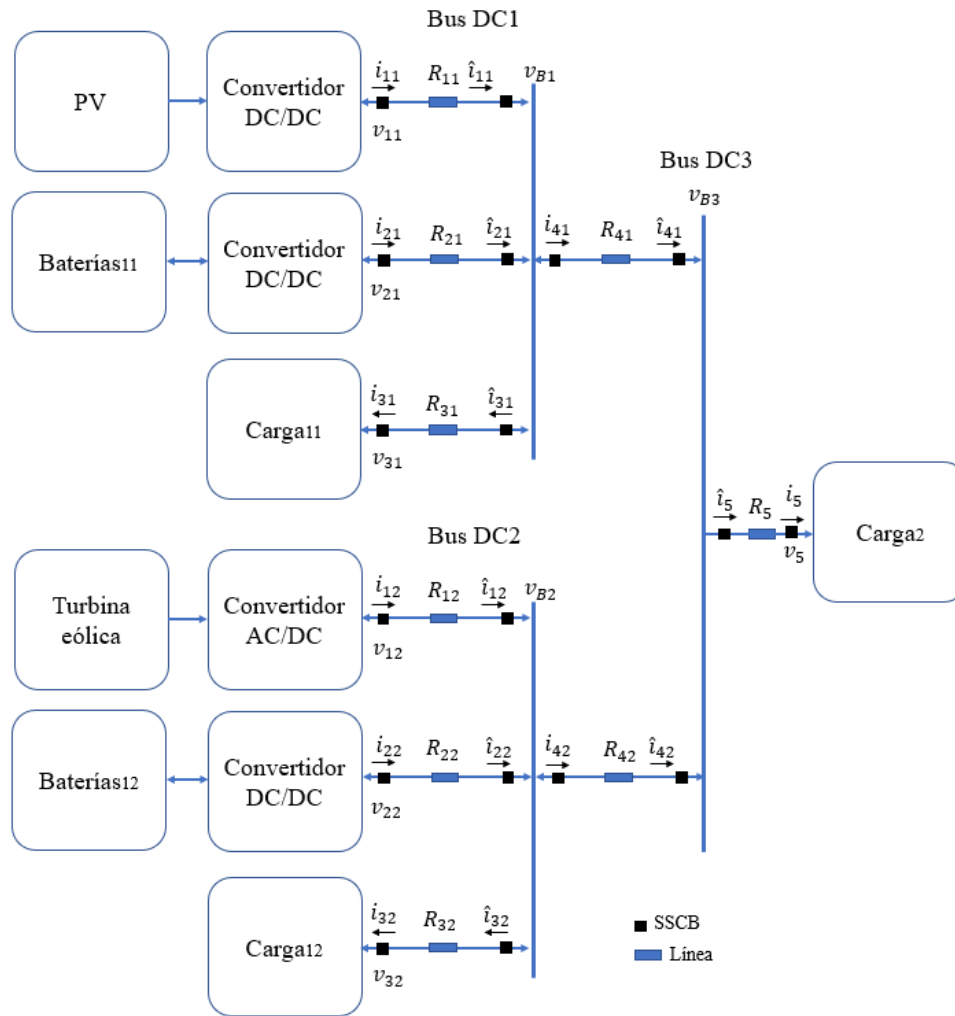


Figura 4.3. Topología y diagrama unifilar de la microrred de estudio para el desarrollo del método de protección de fallas.

Dado que los convertidores y cargas miden y envían los valores de corriente y tensión instantánea a la CPU (*asunción 1* del apartado 4.3.1), las corrientes $[i_{11}, i_{21}, i_{31}, i_{12}, i_{22}, i_{32}, i_5]$ y las tensiones $[v_{11}, v_{21}, v_{31}, v_{12}, v_{22}, v_{32}, v_5]$ son conocidas. Por lo contrario, las corrientes de las líneas i_{41} e i_{42} y las tensiones de buses v_{B1} , v_{B2} , y v_{B3} son incógnitas.

4.3.3.1 Modelo para análisis de falla de cortocircuito

Aplicando el modelo de la Figura 4.1 a todas las líneas de la MR bajo estudio, y planteando las ecuaciones de mallas en las líneas del Bus DC1 y DC3, se obtiene (4.6). $LKV1_{SC}$ - $LKV3_{SC}$ son las ecuaciones obtenidas de la aplicación de la Ley de Kirchhoff de tensión (LKV) en cada malla. $LKV1_{SC}$ se obtiene de la malla del convertidor DC-DC de los paneles fotovoltaicos, el bus DC1, el bus DC3 y la carga2. $LKV2_{SC}$ se obtiene de la malla del convertidor DC-DC de las baterías, el bus DC1, el bus DC3 y la carga2. Finalmente, $LKV3_{SC}$ se obtiene de la malla Carga11, bus DC1, bus DC3 y carga2.

$$\begin{aligned}
LKV1_{SC}: v_{11}-i_{11}R_{11}+i_{f11}\frac{R_{11}}{2}-i_{41}R_{41}+i_{f41}\frac{R_{41}}{2}-i_5R_5-i_{f5}\frac{R_5}{2}-v_5=0 \\
LKV2_{SC}: v_{21}-i_{21}R_{21}+i_{f21}\frac{R_{21}}{2}-i_{41}R_{41}+i_{f41}\frac{R_{41}}{2}-i_5R_5-i_{f5}\frac{R_5}{2}-v_5=0 \\
LKV3_{SC}: v_{31}+i_{31}R_{31}+i_{f31}\frac{R_{31}}{2}-i_{41}R_{41}+i_{f41}\frac{R_{41}}{2}-i_5R_5-i_{f5}\frac{R_5}{2}-v_5=0
\end{aligned} \tag{4.6}$$

La corriente i_{41} es incógnita, pero puede calcularse aplicando la Ley de Kirchhoff de corriente (LKC) al bus DC1:

$$LKC1_{SC}: i_{41}=\hat{i}_{11}+\hat{i}_{21}-\hat{i}_{31}=i_{11}-i_{f11}+i_{21}-i_{f21}-i_{31}-i_{f31} \tag{4.7}$$

Como i_{11} , i_{21} e i_{31} son corrientes conocidas (medidas), i_{41} queda expresada en función de las corrientes incógnitas i_{f11} , i_{f21} e i_{f31} .

Por otro lado, la corriente del nodo de salida (Bus DC3) es:

$$LKC3_{SC}: \hat{i}_5=\hat{i}_{41}+\hat{i}_{42}=i_{41}-i_{f41}+i_{42}-i_{f41} \tag{4.8}$$

Dado que la topología conectada al Bus DC1 y su conexión con el Bus DC3 es simétrica respecto a la topología del Bus DC2 y su conexión con el Bus DC3, el mismo conjunto de ecuaciones (4.6)-(4.7) puede ser reutilizado para el caso de $LKV4_{SC}$ - $LKV6_{SC}$ y $LCK2$, respectivamente. Teniendo esto en cuenta y reemplazando (4.7) en las ecuaciones (4.6), las ecuaciones de todas las ramas ($LKV1_{SC}$ - $LKV6_{SC}$) pueden ser escritas de manera matricial, según (4.9):

$$LKV_{sc}: G \cdot i_f + f = 0 \tag{4.9}$$

donde i_f es el vector de corrientes de falla (incógnitas): $i_f=[i_{f11}, i_{f21}, i_{f31}, i_{f12}, i_{f22}, i_{f32}, i_{f5}, i_{f41}, i_{f42}]'$.

Las componentes del vector f son las constantes de cada ecuación de malla y las componentes de la matriz G son aquellos términos que se multiplican por las corrientes de falla:

$$f = \begin{bmatrix} v_{11}-i_{11}(R_{11}+R_{41})-i_{21}R_{41}+i_{31}R_{41}-i_5R_5-v_5 \\ v_{21}-i_{11}R_{41}-i_{21}(R_{21}+R_{41})+i_{31}R_{41}-i_5R_5-v_5 \\ v_{31}-i_{11}R_{41}-i_{21}R_{41}+i_{31}(R_{31}+R_{41})-i_5R_5-v_5 \\ v_{12}-i_{12}(R_{12}+R_{42})-i_{22}R_{42}+i_{32}R_{42}-i_5R_5-v_5 \\ v_{22}-i_{12}R_{42}-i_{22}(R_{22}+R_{42})+i_{32}R_{42}-i_5R_5-v_5 \\ v_{32}-i_{12}R_{42}-i_{22}R_{42}+i_{32}(R_{32}+R_{42})-i_5R_5-v_5 \end{bmatrix}$$

$$G = \begin{bmatrix} \frac{R_{11}}{2} + R_{41} & R_{41} & R_{41} & \frac{R_{41}}{2} & 0 & 0 & 0 & 0 & -\frac{R_5}{2} \\ R_{41} & \frac{R_{21}}{2} + R_{41} & R_{41} & \frac{R_{41}}{2} & 0 & 0 & 0 & 0 & -\frac{R_5}{2} \\ R_{41} & R_{41} & \frac{R_{31}}{2} + R_{41} & \frac{R_{41}}{2} & 0 & 0 & 0 & 0 & -\frac{R_5}{2} \\ 0 & 0 & 0 & 0 & \frac{R_{12}}{2} + R_{42} & R_{42} & R_{42} & \frac{R_{42}}{2} & -\frac{R_5}{2} \\ 0 & 0 & 0 & 0 & R_{42} & \frac{R_{22}}{2} + R_{42} & R_{42} & \frac{R_{42}}{2} & -\frac{R_5}{2} \\ 0 & 0 & 0 & 0 & R_{42} & R_{42} & \frac{R_{32}}{2} + R_{42} & \frac{R_{42}}{2} & -\frac{R_5}{2} \end{bmatrix}$$

4.3.3.2 Modelo para análisis de falla de circuito abierto

Si se aplica el modelo de la Figura 4.2 a todas las líneas de la MR bajo estudio, y se plantean las ecuaciones de mallas (*LKV*) y nodos (*LKC*) en las líneas asociadas al Bus DC1 y Bus DC3, se obtiene:

$$\begin{aligned} LKV1_{OC}: v_{11} - i_{11}R_{11} - v_{d11} - i_{41}R_{41} - v_{d41} - i_5R_5 - v_{d5} - v_5 &= 0 \\ LKV2_{OC}: v_{21} - i_{21}R_{21} - v_{d21} - i_{41}R_{41} - v_{d41} - i_5R_5 - v_{d5} - v_5 &= 0 \\ LKV3_{OC}: v_{31} + i_{31}R_{31} - v_{d31} - i_{41}R_{41} - v_{d41} - i_5R_5 - v_{d5} - v_5 &= 0 \end{aligned} \quad (4.10)$$

Para escribir las ecuaciones de nodo, se supone que no hay falla de cortocircuito por lo que las ecuaciones de corrientes de línea (4.7) y (4.8) pueden ser reutilizadas considerando las corrientes de fallas iguales a 0:

$$LCK1_{OC}: i_{41} = i_{11} + i_{21} - i_{31} \quad (4.11)$$

El conjunto de ecuaciones (4.11) y (4.12) puede ser planteado para el bus DC2.

$$LCK3_{OC}: i_5 = i_{41} + i_{42} \quad (4.12)$$

Siguiendo el mismo procedimiento aplicado al caso de cortocircuito, las ecuaciones de malla para circuito abierto (*LKV1_{OC}*-*LKV6_{OC}*) pueden ser escritas de manera matricial, según (4.13):

$$LKV_{OC}: H \cdot v_d + b = 0 \quad (4.13)$$

donde v_d es un vector que contiene las fuentes virtuales: $v_d = [v_{d11}, v_{d21}, v_{d31}, v_{d12}, v_{d22}, v_{d32}, v_{d5}]'$.
b y H son:

$$b = \begin{bmatrix} v_{11} - i_{11}R_{11} - i_{41}R_{41} - i_5R_5 - v_5 \\ v_{21} - i_{21}R_{21} - i_{41}R_{41} - i_5R_5 - v_5 \\ v_{31} + i_{31}R_{31} - i_{41}R_{41} - i_5R_5 - v_5 \\ v_{12} - i_{12}R_{12} - i_{42}R_{42} - i_5R_5 - v_5 \\ v_{22} - i_{22}R_{22} - i_{42}R_{42} - i_5R_5 - v_5 \\ v_{32} + i_{32}R_{32} - i_{42}R_{42} - i_5R_5 - v_5 \end{bmatrix}$$

$$H = \begin{bmatrix} -1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 & -1 \\ 0 & -1 & 0 & -1 & 0 & 0 & 0 & 0 & -1 \\ 0 & 0 & 1 & -1 & 0 & 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & -1 \\ 0 & 0 & 0 & 0 & 0 & -1 & 0 & -1 & -1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 & -1 \end{bmatrix}$$

4.3.4 Algoritmo de protección

El diagrama de flujo del algoritmo se expone en la Figura 4.4.

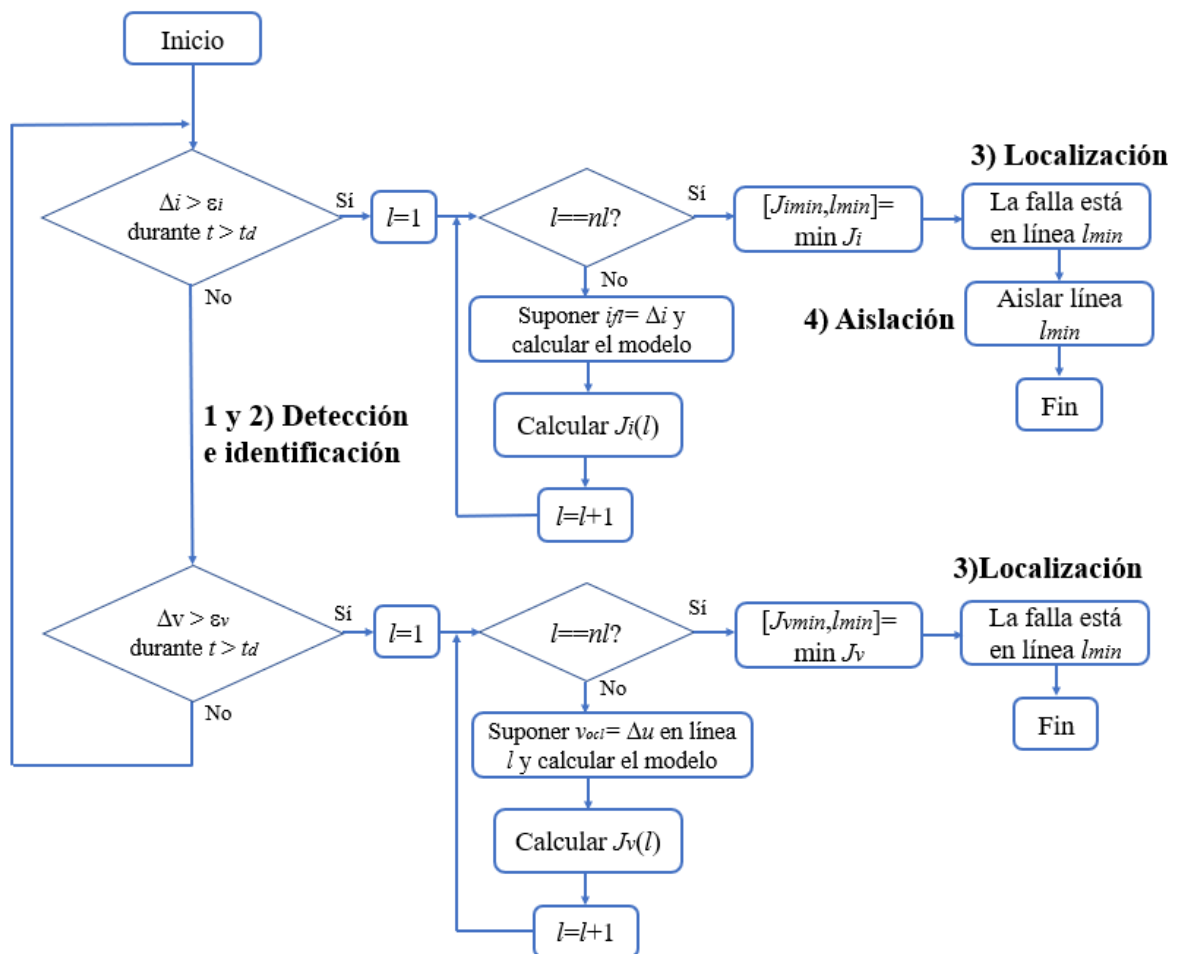


Figura 4.4. Algoritmo para la detección, identificación, localización y aislación de falla.

El método consiste en las etapas de 1) detección, 2) identificación, 3) localización y 4) aislación de fallas. Las etapas de detección e identificación se ejecutan simultáneamente, pero de manera secuencial respecto al tipo de falla. Esto quiere decir que primero se detecta/identifica la falla de cortocircuito y, en caso de no existir, continúa con la detección/identificación de falla de circuito abierto. Esto se debe a que el criterio de detección de cortocircuito es inequívoco (apartado 4.3.4.1), mientras que el de circuito abierto requiere que las corrientes de falla sean cero (apartado 4.3.4.2). En ambos casos, las etapas 3 y 4 se ejecutan únicamente si en la etapa 1 se detectó una falla.

Los criterios utilizados para la detección de ambos tipos de fallas son diferenciales, calculando la diferencia planta-modelo (Δi para cortocircuito y Δv para circuito abierto). Una vez detectada e identificada la falla, se localiza a partir de la evaluación de una función costo de cortocircuito (J_i) o de circuito abierto (J_v), según corresponda. Estas funciones costos se calculan iterativamente para cada línea posible l (número de línea que la identifica) de las líneas totales nl (cantidad de líneas de la MR). La línea l_{min} que minimice dichas funciones, es la candidata más probable a contener la falla. Posteriormente se realiza la aislación.

El procedimiento de detección/identificación/localización de falla de cortocircuito se detalla en el apartado 4.3.4.1, el de circuito abierto en el apartado 4.3.4.2 y el de aislación de fallas en el apartado 4.3.4.3.

4.3.4.1 Falla de cortocircuito

La detección de cortocircuito se basa en la evaluación de la diferencia entre la corriente entregada por los generadores y la absorbida por las cargas, considerando un umbral de disparo ε_i . Si los generadores entregan más corriente que la demandada por las cargas, se supone la existencia de una corriente de fuga Δi . Si el criterio (4.14) se cumple para un tiempo mayor a un tiempo de disparo de falla (t_d), entonces se detecta e identifica la falla de cortocircuito:

$$\sum_{g=1}^m i_G - \sum_{l=1}^n i_L = \Delta i \geq \varepsilon_i \quad (4.14)$$

Luego de que se detecta e identifica el cortocircuito, se localiza la falla a partir de la resolución de un problema simple de optimización. Teniendo en cuenta la *asunción 2* del apartado 4.3.1, la hipótesis para la localización consiste en considerar la falla en un único lugar

a la vez, es decir anular todas las corrientes de falla excepto la de la línea l y considerarla igual a la corriente de fuga Δi . Finalmente se calcula la función costo de cortocircuito $J_i(l)$ como la función cuadratura del error de (4.9), que cuantifica la diferencia planta-modelo para la hipótesis de la falla en la línea l :

$$J_i(l) = (G \cdot i_f + f)' \delta (G \cdot i_f + f) \quad (4.15)$$

donde δ es la matriz identidad.

La línea l_{min} que arroje el valor mínimo de la función costo (4.15), es la que probablemente contenga la falla. Luego se aísla a través de los SSCB.

4.3.4.2 Falla de circuito abierto

Por otro lado, la metodología de detección y ubicación de las fallas de circuito abierto es análoga a la de cortocircuito. El criterio de detección de circuito abierto utiliza la diferencia planta-modelo de las ecuaciones de malla (4.9), considerando que no existe en la MR una falla de cortocircuito, condición que debe evaluarse previamente. Bajo esta condición (donde $i_f=0$), los términos $G \cdot i_f + f$ de las tensiones de malla de (4.9) se reducen a f . Si la diferencia planta-modelo es superior a un umbral de disparo ε_v en alguna de las ramas y por un tiempo mayor a t_d , entonces se detecta e identifica la falla de circuito abierto. Esta condición se expresa en (4.16).

$$|f| = \Delta v \geq \varepsilon_v \quad (4.16)$$

Una vez detectada la falla, se localiza a partir de ubicarla hipotéticamente en cada una de las líneas y evaluando la función costo $J_v(l)$ asociada a cada caso. La función costo J_v para la localización de la línea abierta es la función cuadratura del error de (4.13):

$$J_v(l) = (H \cdot v_{oc} + b)' \lambda (H \cdot v_{oc} + b) \quad (4.17)$$

donde λ es una matriz identidad.

La ubicación l_{min} que arroje el valor mínimo de la función costo (4.17), representa la línea con mayor posibilidad de contener la falla.

4.3.4.3 Aislación de la falla

Para aislar la falla sin necesidad de agregar comunicación entre los CBs y la CPU, se propone utilizar el bus DC como medio de comunicación a través de modulación de armónicos y la *asunción 4* del apartado 4.3.1. Una metodología similar fue propuesta en [31]. Se monta una señal armónica sobre la señal de potencia y, en función del armónico inyectado en el bus, se activa el CB específico deseado. Además, se supone que la CPU puede enviar la señal de desconexión a un convertidor de manera de que aisle su salida.

4.4 Entorno de simulación para la evaluación del método

En esta sección se desarrolla un modelo de simulación de una pequeña MR de interés regional, similar a la presentada en el Caso 1 de estudio en el Capítulo 3. El modelo desarrollado tiene un alto nivel de detalle para poder evaluar el desempeño del método propuesto en la Sección 4.3 de la manera más real posible.

4.4.1 Caso de Estudio

Se propone una topología típica de microrred aislada, basada en la presentada como Caso 1 de estudio en el Capítulo 3 (Figura 3.1). Está integrada por generación fotovoltaica, almacenamiento en baterías y un grupo de cargas de AC. La potencia nominal en paneles es de 8.53 kW_p, la capacidad nominal de las baterías es 3 kWh y la demanda máxima de la carga es 6 kW. En el bus DC se conectan los convertidores DC-DC de los paneles fotovoltaicos y de las baterías, estas últimas encargadas de regular la tensión del bus en 400 V. El bus DC se conecta a la alimentación del inversor monofásico (convertidor DC-AC) que abastece las cargas AC, como se ve en la Figura 4.5.

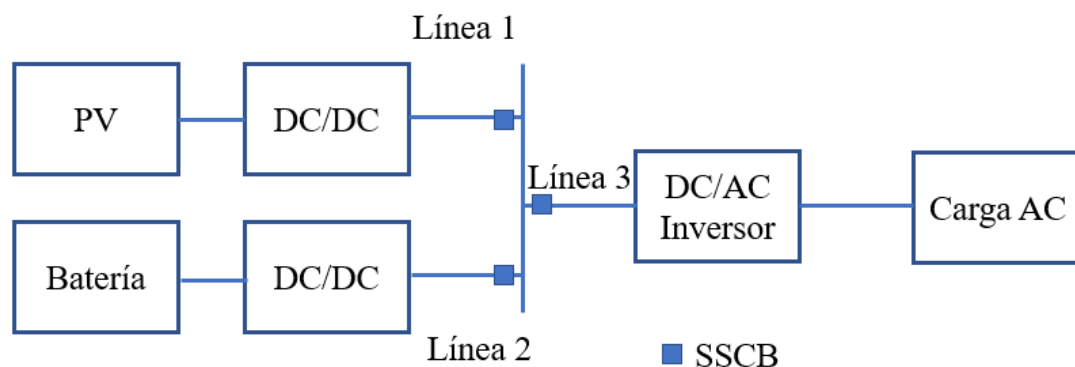


Figura 4.5. Topología de la microrred simulada.

4.4.2 Modelo de la microrred

El objetivo de este apartado es desarrollar un entorno de simulación detallado para evaluar, de la manera más real posible, el desempeño del método en la MR bajo estudio. Por este motivo, el modelo de simulación de las líneas es resistivo-inductivo, a diferencia de los modelos de fallas antes propuestos. Además, los convertidores electrónicos incorporan controladores primarios (control con escala de tiempo pequeña).

Las baterías son de gel, con una tensión nominal de 200 V, una capacidad de 15 Ah y el estado de carga (*state of charge*, SoC) mínimo permitido es de 20 % (valor típico para cuidar la vida útil). El arreglo de paneles está compuesto por 4 ramas en paralelo de 10 paneles en serie en cada rama, siendo la potencia por panel de 213.15 W_p (modelo Soltech 1STH-215-P).

4.4.2.1 Líneas de microrred

El modelo de simulación para las líneas de la MR es resistivo-inductivo de modo que la simulación sea lo más real. Ambos parámetros pueden calcularse considerando un conductor específico [117].

En el bus DC se conectan el convertidor de los paneles fotovoltaicos, el convertidor de las baterías y el inversor. Los conductores de todas las líneas se suponen de la misma sección, AWG 10. La longitud del tramo asociado al convertidor de los paneles se supone de 15 metros (línea 1, resistencia total de la línea = 98.38 mΩ y 28.3 μH), la del tramo del convertidor de las baterías se supone de 5 metros (línea 2, resistencia total de la línea= 32.7 mΩ y 8.5 μH) y 10 metros el asociado al tramo del bus DC a la entrada del inversor (línea 3, resistencia total de la línea=65.5 mΩ y 18.2 μH).

4.4.2.2 Convertidor DC-DC de los paneles fotovoltaicos

El convertidor consta de una etapa elevadora o *boost* (Figura 4.6) funcionando en modo continuo controlada por un algoritmo MPPT P&O (Perturbar y Observar) [118] que permite absorber la máxima potencia de los paneles fotovoltaicos. El algoritmo MPPT P&O es un algoritmo sencillo que funciona mediante la perturbación periódica del ciclo de trabajo del convertidor, midiendo la potencia de salida de los paneles fotovoltaicos y comparándola con la potencia obtenida con la perturbación anterior. Si al incrementar el ciclo de trabajo, la potencia de salida aumenta, el algoritmo continuará la perturbación en dicha dirección; en caso

contrario, decrementará el ciclo de trabajo. De esta manera, el algoritmo busca continuamente el punto de máxima potencia [119].

Por otro lado, el principio de funcionamiento del convertidor elevador se basa en la elevación de tensión que se produce en el inductor durante la conmutación del transistor producida por una señal PWM [120]. Cuando el transistor está activado, la corriente fluye a través del inductor y del transistor. En este momento la energía se almacena en el inductor. Al desactivarse el transistor, la corriente del inductor que no puede circular por el transistor comienza a circular por el diodo, el capacitor de salida y la carga. En este momento la tensión del inductor se suma a la de la entrada, incrementando el voltaje de salida. El transistor utilizado es un MOSFET dada la elevada frecuencia de conmutación (20 kHz). La potencia nominal del convertidor es de 8.53 kW (igual a la potencia nominal en paneles) y su corriente nominal es de 22 A. La bobina tiene una inductancia de 2 mH y un valor resistivo de 100 mΩ. Los capacitores de entrada y salida son iguales, tienen una capacidad de 500 μF y una resistencia de 4.2 mΩ [121].

Cuando la corriente de salida es superior a 100 A por un tiempo de 900 μs, la protección de cortocircuito se activa y abre el circuito mediante el relé de estado sólido de salida. El varistor protege de sobretensiones los componentes conectados al bus DC y se modela siguiendo su curva característica de tensión vs corriente.




Figura 4.6. Esquema del convertidor DC-DC de los paneles fotovoltaicos.

4.4.2.3 Convertidor DC-DC de las baterías

Este convertidor implementa una etapa reductora-elevadora (*buck-boost*) bidireccional (Figura 4.7). El funcionamiento como elevador se logra conmutando el transistor del lado inferior (a través de S2), mientras que el transistor del lado superior funciona como diodo. Durante esta operación, el principio de funcionamiento es el mismo que el descrito en el apartado 4.4.2.2. Por otro lado, el funcionamiento como reductor se logra conmutando el transistor del lado superior (a través de S1), mientras el transistor del lado inferior funciona como diodo [122]. Los transistores se controlan a través de PWM con una frecuencia de

conmutación de 20 kHz. La bobina tiene una inductancia de 3 mH y una resistencia de 100 mΩ, mientras que los capacitores de entrada y salida tienen una capacidad de 500 μF y una resistencia de 4.2 mΩ [123].

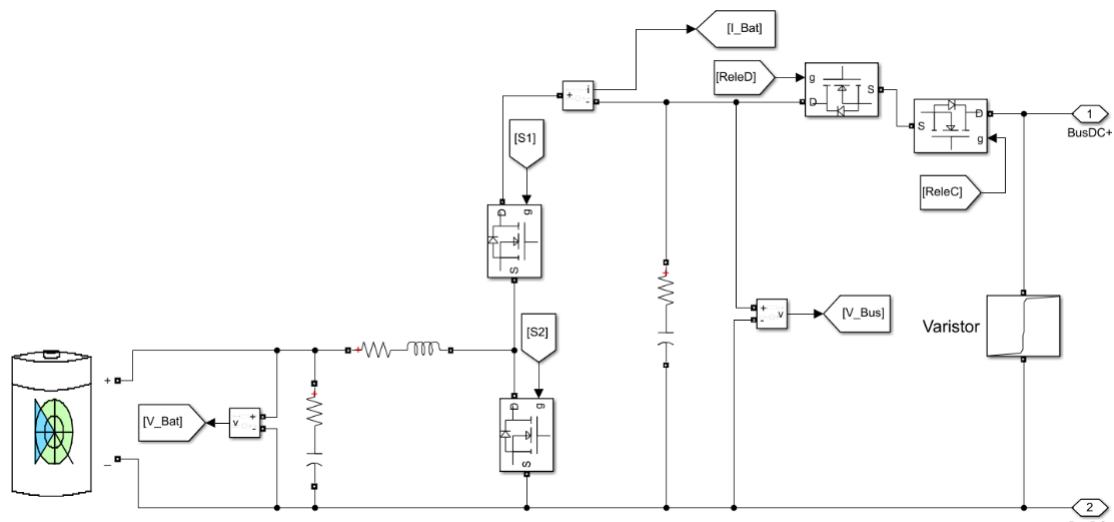


Figura 4.7. Esquema del convertidor (elevador-reductor) de las baterías.

El convertidor regula la tensión del bus DC en 400 V a través de la carga y descarga de las baterías. El convertidor y las baterías funcionan como una fuente de corriente: las baterías deben absorber corriente cuando la tensión del bus supera los 400 V (exceso de generación fotovoltaica respecto a la demanda de la carga), e inyectar corriente en caso contrario (generación solar insuficiente) [124]. Esta lógica se implementa dentro de dos controladores PID (uno para carga y otro para descarga) que utilizan la tensión de salida (V_Bus) como señal de realimentación, sintonizados a través del método Tyreus-Luyben [125].

El sistema de gestión de baterías actúa sobre el control del convertidor protegiendo las baterías de sobrecarga y descarga excesiva, evitando la carga cuando el SoC es del 100 % (baterías cargadas), y la descarga cuando el SoC es menor o igual al 20 % (baterías descargadas). Esta protección se logra mediante la activación y desactivación de los transistores de salida. Las baterías se encargan de alimentar total o parcialmente la carga cuando la generación fotovoltaica es insuficiente pero también entregan los picos de potencia durante la conexión de cargas con elevada demanda (por ejemplo, motores), estabilizando la tensión del bus. Estos picos de potencia pueden ser varias veces la potencia nominal de las baterías. Por esto, la potencia del convertidor es mayor a la potencia nominal de las baterías. La protección de cortocircuito actúa sobre el transistor de salida cuando la corriente es superior a 120 A durante 1 ms.

4.4.2.4 Inversor

El modelo se basa en el convertidor DC-AC del inversor monofásico sin transformador ABB UNO DM 6.0 PLUS, con potencia nominal de 6 kW y una corriente de 27 Arms. Está compuesto por un puente H de transistores MOSFET y un filtro de salida LC (Figura 4.8). El inversor posee protecciones de salida de sobrecarga y cortocircuito, además de protecciones contra sobretensiones tanto en la entrada como en la salida a través de varistores. La protección de sobrecarga permite que el inversor pueda entregar una corriente superior a la nominal durante un período de tiempo pequeño antes que la protección se active (2.5 veces la corriente nominal durante un tiempo de 3 s), permitiendo el arranque de cargas, como por ejemplo motores. La protección de cortocircuito es más rápida y se activa a partir de un límite de corriente mayor (160 A por un tiempo de 1.6 ms) [126].

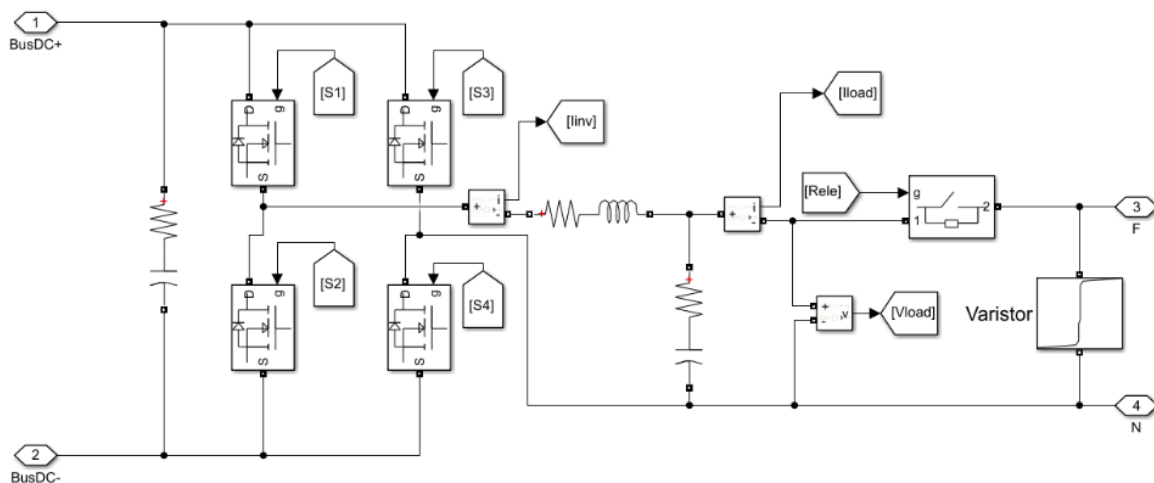


Figura 4.8. Esquema del inversor.

El capacitor del puente H tiene una capacidad de 500 μF y una resistencia de 4.2 $\text{m}\Omega$. El capacitor del filtro LC tiene el mismo valor resistivo y una capacidad de 6.8 μF . La bobina tiene una inductancia de 4 mH y una resistencia de 100 $\text{m}\Omega$. La modulación utilizada es SPWM unipolar, implementada con dos controladores PI conectados en cascada con realimentación de corriente y tensión (control de múltiples lazos) para lograr estabilidad en estado estacionario y un correcto desempeño durante transitorios [127]. La corriente por el inductor del filtro (que es la corriente del inversor i_{inv}) actúa como parámetro del bucle interior, y la tensión de salida (que es la tensión en la carga V_{load}) como parámetro del bucle exterior (Figura 4.9).

La corriente por el inductor es la suma de la corriente de la carga (I_{load}) y la del capacitor (I_{cap}). Por otro lado, la tensión de salida del puente H es la suma de la caída de tensión en el inductor (V_L) y la tensión en la carga (V_{load}). La señal de referencia obtenida V_{ref} se utiliza para obtener la modulación de los transistores.

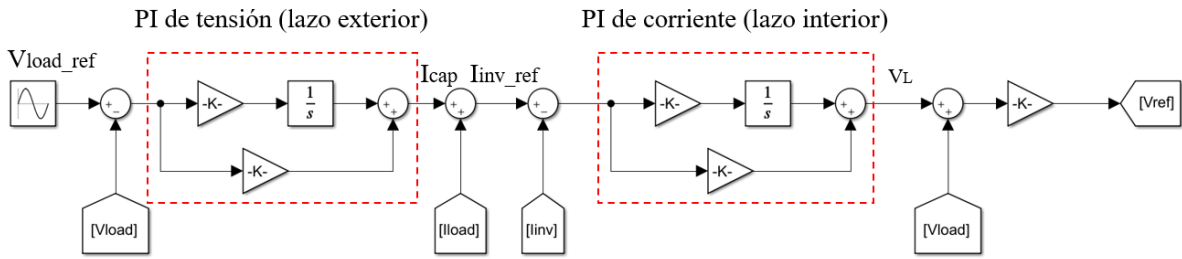


Figura 4.9. Controladores de corriente y tensión del inversor.

Para lograr baja distorsión armónica se utiliza *Sinusoidal Pulse Width Modulation* (SPWM), en la cual las señales aplicadas a los transistores del puente H se obtienen de la comparación de la tensión de referencia V_{ref} (en fase y contrafase), determinada por los controladores, con una señal triangular (Figura 4.10).




Figura 4.10. Generación de las señales de los transistores del inversor.

4.4.3 Simulaciones y resultados

Se simula el sistema de tiempo continuo utilizando un *solver* de paso variable. Las fallas se ejecutan en todos los casos en un tiempo igual a 0.5 s, siendo 0.6 s el tiempo de simulación total. Los parámetros de protección son $\epsilon_i = 2$ A, $\epsilon_v = 5$ V y $t_d = 800$ μ s.

Se analizan algunos escenarios de interés, evaluando el desempeño del esquema frente a fallas de cortocircuito, circuito abierto producidos en el lado DC y cambios repentinos en la carga. Además, se proponen escenarios de falla en los que las protecciones tradicionales no son efectivas (por ejemplo, con radiación solar baja o baterías descargadas). En la Tabla 4.1 se muestra la parametrización de los escenarios simulados. Cada escenario se define por el estado de la carga, la radiación solar sobre los paneles, la carga conectada al inversor, la resistencia de falla en caso de cortocircuito, la línea que posee la falla, el tipo de falla y su ubicación expresada en porcentaje de la longitud de la línea. Las fallas de cortocircuito se denominan SC (*short circuit*) y las de circuito abierto OC (*open circuit*). En el escenario 1, no existe falla, pero

se conecta en paralelo a la carga de 30Ω del lado AC, otra carga pulsante de igual impedancia, que está activa por 100 ms; el método no detecta este cambio repentino como una falla del sistema. Por otro lado, los escenarios 2 – 6 resultan de particular interés desde un enfoque de resiliencia de la MR, porque la falla se produce en la línea asociada a los convertidores de los paneles fotovoltaicos. En este caso, el método propuesto aísla la falla rápidamente (más rápido que las protecciones de corriente asociado a las baterías) de modo que la MR continúa abasteciendo la carga a través de las baterías, que tienen suficiente carga para hacerlo. Se observa que el método detecta y aísla la falla correctamente en el tramo asociado a la generación fotovoltaica incluso con resistencias de cortocircuito elevada ($R_f=100 \Omega$) y que también detecta y aísla la falla en este tramo incluso cuando la radiación solar es nula (escenario 5 y 6).

Escenario	SoC %	Radiación [W/m ²]	Carga AC [Ω]	R_f [Ω]	Línea con falla	Tipo de falla	Ubicación % línea	¿Funciona?
1	50	1000	30	-	-	-	-	Sí
2	50	1000	30	10	1	SC	20	Sí
3	50	500	30	100	1	SC	50	Sí
4	50	1000	30	10	1	SC	80	Sí
5	50	0	30	10	1	SC	80	Sí
6	50	0	15	30	1	SC	50	Sí
7	20	500	30	1	2	SC	20	Sí
8	20	500	30	1	2	SC	50	Sí
9	20	1000	10	10	2	SC	80	Sí
10	20	1000	30	10	3	SC	20	Sí
11	50	500	30	30	3	SC	50	Sí
12	50	500	30	30	3	SC	80	Sí
13	50	1000	30	-	1	OC	-	Sí
14	50	1000	30	-	2	OC	-	Sí
15	50	1000	30	-	3	OC	-	Sí

Tabla 4.1. Escenarios de falla simulados.

Las salidas del esquema de protección para el escenario 3, se muestran en la Figura 4.11. Las salidas se identifican a través del tipo de falla que detectan (es decir, OC o SC) y un número que indica la línea asociada. El pequeño retraso que se observa desde la ejecución de la falla (que se ejecuta a los 0.5 s) hasta la detección/identificación de la misma se asocia a que la falla tiene una resistencia elevada en este caso, al parámetro ϵ_i de corriente setado y al tiempo de detección t_d .

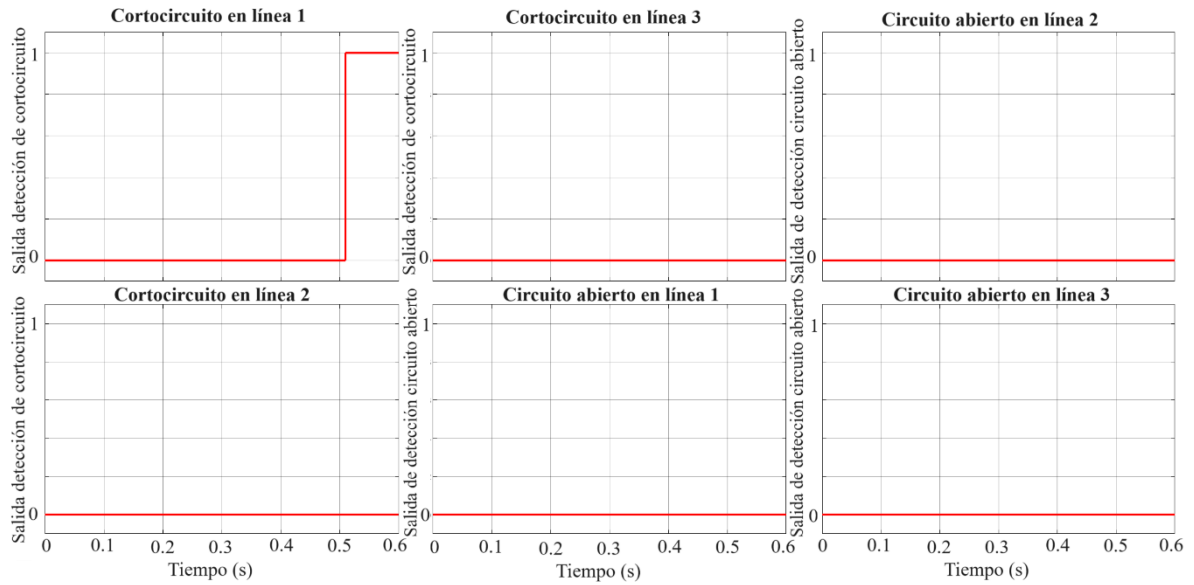


Figura 4.11. Detección/identificación del método para escenarios 3.

Las señales de corriente para el escenario 3 se muestran en la Figura 4.12, donde en azul se aprecian las señales de tensión y en rojo las de corriente. Los cuadrantes representan las señales a la salida del convertidor de los paneles (arriba, a la izquierda), las del convertidor de las baterías (abajo, a la izquierda), las de entrada del inversor (arriba, a la derecha) y las de salida del inversor (abajo, a la derecha). Al producirse el cortocircuito e identificarlo, se aísla la falla a través del SSCB correspondiente, permitiendo que la carga se alimente correctamente a través de la batería, una vez reestablecido su control, luego de la caída de tensión. La corriente positiva de la batería indica que las mismas entregan potencia, mientras que valores negativos indican un proceso de carga.




Figura 4.12. Señales de corriente y tensión del escenario 3.

Cuando las baterías están descargadas (SoC mínimo de 20%) no pueden aportar corriente al cortocircuito ya que el BMS desactiva el transistor de descarga del convertidor. Bajo estas condiciones, las protecciones tradicionales de corriente no funcionan. Inclusive las protecciones asociadas a los paneles fotovoltaicos tampoco, dado que los mismos operan como fuente de corriente por lo que su corriente de cortocircuito es limitada. Estas condiciones son las que se simulan en los escenarios 7 – 9. Se observa, además, que las fallas se ejecutan justamente en la línea de las baterías. En el escenario 9, la resistencia de falla es elevada y la potencia de la carga también. Aun así, el método detecta y aísla la falla, permitiendo que la carga se alimente únicamente a través de la generación fotovoltaica dado que la radiación solar es elevada (de 1000 W/m^2). En todos los casos, se logró identificar correctamente la falla en la línea 2 correspondiente a las baterías (Figura 4.13),

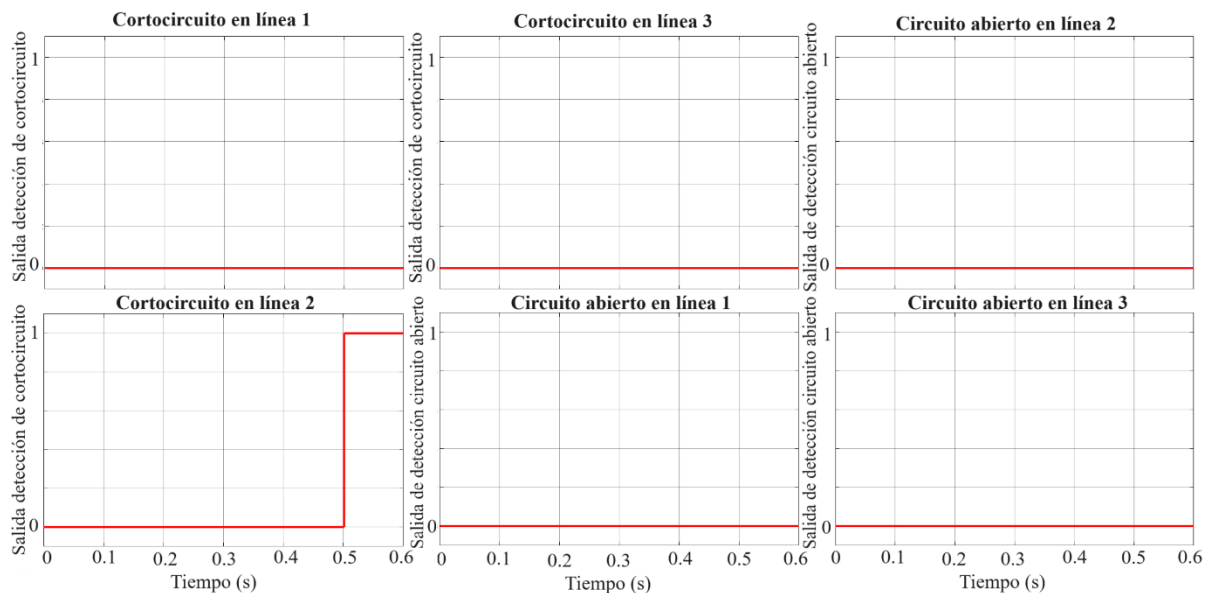


Figura 4.13. Detección/identificación del método para escenarios 7 – 9.

Los escenarios 10 – 12, poseen fallas en la línea 3, asociada a la entrada del inversor por lo que la carga no puede ser abastecida en estos casos. Sin embargo, la energía generada por los paneles puede ser aprovechada para cargar las baterías, como se ve en la Figura 4.15 (señales correspondientes al escenario 11). Las fallas fueron identificadas en los tres escenarios mencionados, según la Figura 4.14.




Figura 4.14. Detección/identificación del método para escenarios 10 – 12.




Figura 4.15. Señales de corriente y tensión del escenario 11.

Frente a fallas de circuito abierto, el esquema funcionó correctamente en los tres escenarios propuestos (13 – 15) en los que se abren cada una de las posibles líneas. La identificación de la falla para el escenario 13 se expone en la Figura 4.16. Al abrirse la línea asociada a la generación fotovoltaica, la misma se aísla a través del CB y desactivando la salida del convertidor, según se muestra en la Figura 4.17. Las baterías, que estaban siendo cargadas previamente a la falla, comienzan a abastecer la carga.

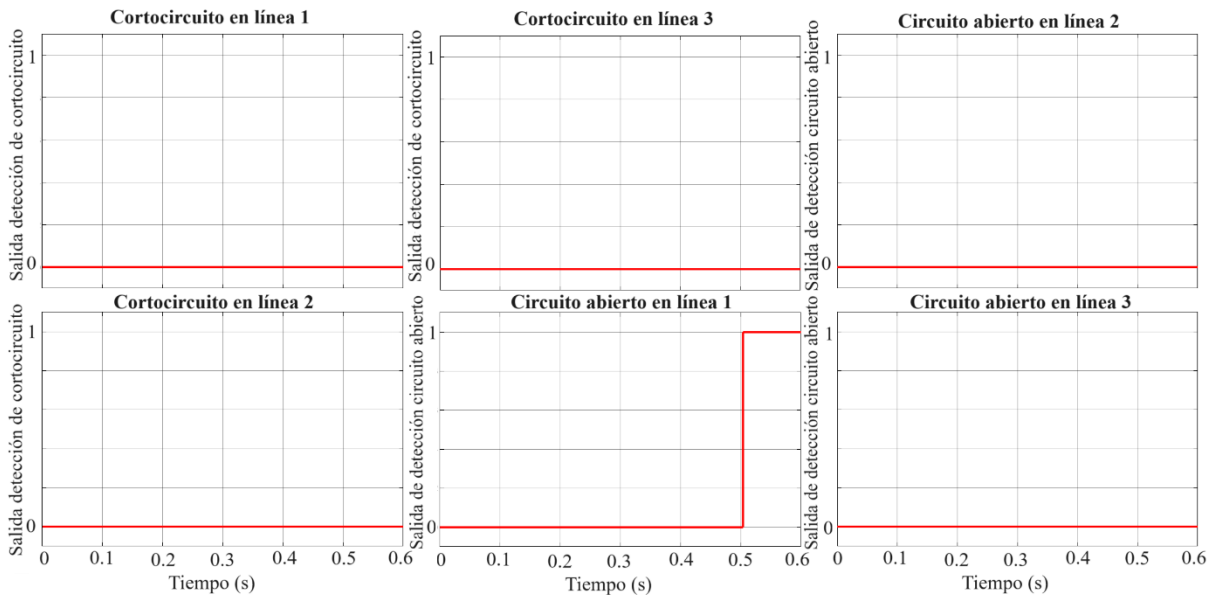


Figura 4.16. Detección/identificación del método para el escenario 13




Figura 4.17. Señales de corriente y tensión del escenario 13.

4.5 Discusión

El esquema propuesto de protección para microrredes DC tiene un enfoque particularmente práctico ya que posee un bajo costo computacional (se basa en la resolución de ecuaciones algebraicas sencillas) y utiliza parámetros fácilmente calculables, como el valor de las resistencias de las líneas y los valores umbrales de detección. Además, requiere de pocas mediciones en comparación a otros métodos basados en la comunicación, dado que utiliza únicamente los valores de corriente y tensión de los dispositivos finales, como convertidores y cargas, sin considerar los de los buses.

Por otro lado, se desarrolló un entorno de simulación detallado de gran utilidad para analizar fallas de distinta naturaleza en una microrred aislada. Este entorno también permite evaluar el comportamiento del método de protección frente a cambios en la generación o en la carga, condiciones que pueden ocasionar falsas detecciones en otros métodos, particularmente aquellos que se basan en señales.

Las simulaciones de circuito abierto muestran que, para la microrred propuesta, el método funcionó correctamente en todos los escenarios evaluados. Lo mismo sucede para las simulaciones de cortocircuito, donde se logró identificar y aislar las fallas incluso sin importar la ubicación de la misma sobre la línea, y para distintos valores de resistencias de cortocircuito. Esto a pesar de incorporar diferencia planta-modelo en las simulaciones, donde las líneas de alimentación se consideran resistivas-inductivas a diferencia de los modelos de fallas propuestos, donde se consideran puramente resistivas. Además, el esquema detecta y aísla fallas incluso en escenarios donde las protecciones tradicionales de corriente no funcionan. Estos escenarios difíciles de detectar suceden principalmente cuando las baterías están descargadas, debido a que las baterías tienen una corriente de cortocircuito elevada, mientras que la de los paneles fotovoltaicos es limitada.

Capítulo 5

DISEÑO, INSTALACIÓN Y PUESTA EN MARCHA DE GENERACIÓN FOTOVOLTAICA EN GRANJA AVÍCOLA DE ENTRE RÍOS

5.1 Resumen del capítulo

El nuevo marco legal de Generación Distribuida y Generación Renovable de la provincia de Entre Ríos busca fomentar el desarrollo de microrredes con integración de energía renovable. Como se mencionó en el Capítulo 3, la industria avícola es una de las actividades económicas más importantes de la provincia. Por los requerimientos de climatización que estas granjas necesitan para la salud de las aves, la demanda de potencia y el consumo de energía durante el verano es muy elevado. En este capítulo, se describen las etapas de dimensionamiento, simulación económica, instalación, puesta en marcha y conexión a la red de distribución de un parque solar de 24 kW_p de potencia instalada en una granja avícola ubicada en la provincia de Entre Ríos. El dimensionamiento y simulación se realizó mediante el software de microrredes HOMER Pro®, utilizando la información de facturación suministrada por el usuario. La generación fotovoltaica se conectó a la red de distribución el 1° de febrero de 2023, siendo una de las primeras en la provincia para este nivel de potencia. Desde el momento de la conexión hasta el 1° de febrero de 2024, la instalación generó 35658 kWh de los cuales 9843 kWh fueron consumidos por las cargas y el excedente fue inyectado. Durante este período, la instalación fotovoltaica brindó una reducción del 31% (reducción de USD 3738) del costo de energía en relación al caso hipotético de la misma granja sin generación. Sin embargo, se evalúa un segundo caso hipotético, que incorpora 24 kW_p de generación fotovoltaica, pero también una gestión ideal de la energía. En este caso, la reducción fue del 64% (reducción de USD 7676). Esto se produce por la relación del costo de venta/compra de energía y la conveniencia de autoconsumo.

5.2 Introducción

La Ley Nacional 27191 (“Régimen de Fomento Nacional para el Uso de Fuentes Renovables de Energía Destinada a la Producción de Energía Eléctrica”), sancionada y promulgada en el año 2015, establece obligaciones de consumo de energía renovable para grandes usuarios, además de la creación de un fondo especial para el desarrollo de estos

proyectos (FODER) [128]. Las obligaciones para los períodos anteriores al año 2024 establecían que, para fines del 2017, los grandes usuarios del mercado eléctrico mayorista y las grandes demandas de las distribuidoras -con potencias superiores a 300 kW-, debían incorporar mínimamente el 8% de energía renovable respecto a su consumo total. Para los años 2019, 2021 y 2023 dicho valor debía superar el 12%, 16% y 18%, respectivamente. En cuanto a las obligaciones vigentes, para finales del año 2025 asciende al 20%. Si bien las metas de la ley no se han cumplido estrictamente desde su entrada en vigor, el programa sirvió para marcar un rumbo a nivel nacional.

Por otro lado, la Ley Nacional 27424 (“Régimen de Fomento a la Generación Distribuida de Energía Renovable Integrada a la Red Eléctrica”) declara de interés nacional la GD, estableciendo beneficios fiscales (particularmente, un crédito fiscal) para proyectos de GD, creando un fondo de financiamiento para su implementación (FODIS) y un fondo para el desarrollo de tecnología nacional asociada (FANSIGED) [129]. Además, la ley define al modelo de balance neto como método de facturación, en el que el saldo a pagar por el usuario-generador es la diferencia monetaria entre el costo de la energía consumida de la red y el beneficio obtenido por la energía inyectada a la misma. En caso de que el saldo sea favorable al usuario, se estipula la configuración de un crédito para los próximos períodos.

En Entre Ríos, la entrada en vigencia de la Ley Provincial 10933 (“Utilización de Fuentes Renovables de Energía para la Generación de Energía Eléctrica Destinada al Mercado Eléctrico”), reglamentada en el año 2023 a través del Decreto 324/2023 del MPIyS (Ministerio de Planeamiento, Infraestructura y Servicios), está impulsando actualmente el desarrollo de proyectos de GD basados en energía renovable. Esta ley de fomento, sancionada en el 2021, adhiere a las Ley Nacional 27424 antes mencionada por lo que los beneficios económicos y tributarios previstos en la misma se aplican ahora a los proyectos provinciales. Además, se crea un fondo de inversión (FES) financiado en parte por el FODER y el FODIS, y se establece como meta alcanzar el 30% de energía renovable a nivel provincial en el año 2030 [130]. Esta ley y su reglamentación finalmente allanan el camino para el desarrollo de proyectos de GD y GR en la provincia.

Los niveles de radiación solar en Entre Ríos son propicios para la instalación de generación fotovoltaica. A lo largo de su extensión, la provincia posee valores de irradiancia global horizontal que oscilan entre 2.34 y 6.8 kWh/m² para los meses de junio y diciembre, respectivamente, con una media anual de 4.64 kWh/m². Estos valores son comparables con los obtenidos en la ciudad de Barcelona [131].

En este marco, este capítulo expone las etapas llevadas a cabo para instalar 24 kW_p de generación fotovoltaica en una granja avícola ubicada en la localidad de Valle María, Entre Ríos. Se presenta el estudio del caso utilizando información suministrada por el usuario, así como el análisis tecno-económico desarrollado con el software HOMER Pro®, además de la instalación y puesta en marcha de la micro-generación (término utilizado en Entre Ríos para referirse a GD de baja potencia). La conexión a la red de distribución de ENERSA fue realizada el 1º de febrero de 2023, siendo una de las primeras en la provincia con este nivel de potencia.

5.3 HOMER Pro®

HOMER Pro® es una herramienta informática de simulación y dimensionamiento dedicado a MRs. Cuenta con un optimizador que busca la mejor combinación de los componentes de una MR, obteniendo un dimensionamiento óptimo en base al costo actual neto (*Net Present Cost*, NPC) del proyecto [132]. Su funcionamiento se basa en la simulación de la MR con todos sus componentes a lo largo de la vida útil de un proyecto y bajo una gestión de energía determinada.

Este software permite realizar un análisis tecno-económico profundo, estimando la producción de cada generador y la energía desaprovechada en la MR. Para esto, se basa en los recursos del lugar, las características de las cargas a abastecer, las restricciones operativas que se deseen incorporar y en parámetros económicos como tasa de descuento e inflación. La Figura 5.1 muestra un diagrama conceptual del funcionamiento del software.

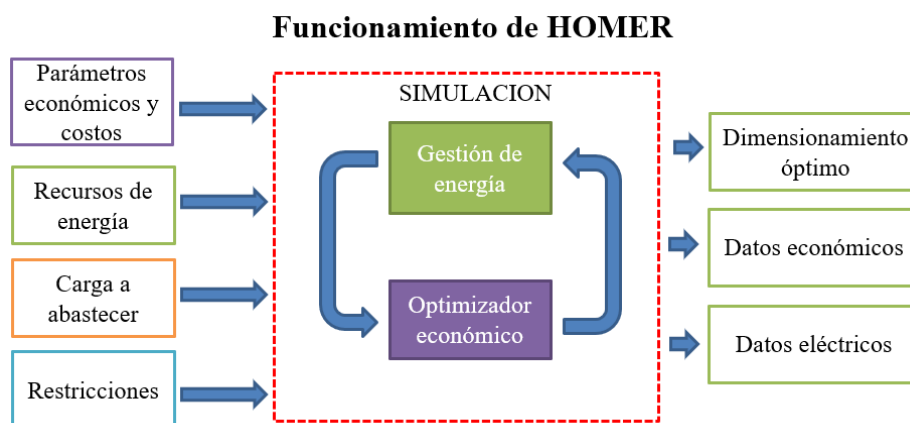


Figura 5.1. Diagrama del funcionamiento de HOMER Pro.

HOMER Pro® posee cinco estrategias de gestión de energía: ciclos de carga, seguimiento de carga, despacho combinado, orden de generador y link de MATLAB (permite al usuario implementar su propia estrategia de gestión).

El *NPC* representa la suma de todos los costos incurridos durante la vida útil del proyecto menos los beneficios obtenidos, traídos a valor presente (valores descontados). Su valor se determina según (5.1) [133]:

$$NPC = \sum_{k=1}^N \left(\sum_{j=1}^M C_{jk} - B_k \right) a_k, \text{ con } a_k = \frac{1}{(1+i)^k} \quad (5.1)$$

donde M es la cantidad de componentes de la MR (generadores, dispositivos de almacenamiento y convertidores), N es la vida útil del proyecto (expresada en años), C_{jk} es el costo total del componente j durante en el año k y B_k es el beneficio obtenido en dicho período. Cada costo C_{jk} incluye costo de capital, costo de recambio, costos de operación y mantenimiento, gasto en combustibles, penalidad por emisiones y costo de compra de energía a la red. El beneficio B_k incluye el valor remanente de los equipos al final de la vida útil del proyecto (*salvage*) y la venta de energía a la red. El factor de descuento a_k en (5.1) depende de la tasa de descuento real i dada por [134]:

$$i = \frac{i_n \cdot f}{1+f} \quad (5.2)$$

donde i_n es la tasa de descuento nominal y f es la tasa de inflación. La tasa de descuento es un factor financiero que se utiliza para convertir el dinero del futuro en dinero actual o presente y representa la tasa de rentabilidad mínima que se debe exigir a una inversión. En el cálculo de la rentabilidad de los proyectos de inversión, se suele definir la tasa de descuento como aquella que corresponde al coste de los recursos financieros utilizados para ejecutar dicha inversión. Estos recursos financieros pueden ser: i) propios: con aportaciones del inversor (capital), ii) ajenos: con aportaciones de acreedores (deuda, préstamos bancarios, etc.) [135].

HOMER Pro® realiza el dimensionamiento óptimo de los componentes a través de la minimización del *NPC* teniendo en cuenta restricciones operativas como penetración mínima de energía renovable, máxima capacidad anual de corte (%), cantidad anual de energía comprada y vendida a la red, entre otras. Por otro lado, también permite incluir penalidades por emisiones de gases de efecto invernadero y/o por exceso de consumo de la red. La formulación general del problema de optimización se describe en (5.3).

$$\min_{x_1, x_2, \dots, x_M} NPC(x_1, x_2, \dots, x_M) = \min \sum_{k=1}^N \left(\sum_{j=1}^M x_j [c_{jk} - b_{jk}] \right) a_k \quad (5.3)$$

s.a

$$x_1, x_2, \dots, x_M \in X$$

donde x_i es la potencia del componente i , y c_{jk} y b_{jk} son el costo y el beneficio por unidad de potencia del componente j en el año k , respectivamente.

El NPC es igual en valor que el valor actual neto (VAN), pero de signo contrario. De este modo, su minimización implica la maximización del VAN.

Otro parámetro económico importante es el costo nivelado de energía (*levelized cost of energy*, LCOE), definido como el costo promedio por kWh de energía eléctrica útil producida por el sistema [136]. Se calcula a través del NPC , según (5.4) [133], [136]:

$$LCOE = \frac{CRF \cdot NPC}{E_{ab}}, \text{ con } CRF = \frac{i(1+i)}{(1+i)^N - 1}, \quad (5.4)$$

donde CRF es el factor de recuperación del capital y E_{ab} es la energía total abastecida a la carga.

5.4 Estudio del caso y propuesta

5.4.1 Normativa y reglamentación

En el año 2022, momento en que se analizó el proyecto, la Ley provincial 10933 ya había sido promulgada (en el año 2021), pero no reglamentada (a inicios del 2023) por lo que aún no estaba vigente. Los procedimientos técnicos para instalar micro-generación se regían por la Resolución 168/20 del EPRE (Ente Provincial Regulador de la Electricidad) y la “Especificación Técnica para la instalación de acometidas en suministros con micro-generación fotovoltaica” de ENERSA. En estas normativas se declara el balance neto como método de facturación y se establecen los siguientes requisitos:

- Potencia instalada de la micro-generación menor o igual a la contratada a la distribuidora.
- El medidor bidireccional de facturación de energía y el medidor de generación deben estar en el pilar de la acometida.

- Conexión entre la micro-generación y la red de distribución luego del medidor bidireccional y antes de la carga del usuario.
- Puesta a tierra de la micro-generación independiente respecto a la puesta a tierra de la distribuidora.
- Circuito de alterna y continua con protecciones de sobretensión, sobre-corriente y descargas a tierra.
- Aislación de la micro-generación y la red de distribución durante operación anormal y reconexión automática al restablecerse los parámetros normales (ver apartado 5.5.2).

5.4.2 Información de la granja

La granja se encuentra en Valle María, una localidad ubicada 30 km al sur de la ciudad de Paraná. Su localización se muestra en la Figura 5.2, siendo sus coordenadas geográficas (-31.994290, -60.624035).



Figura 5.2. Ubicación de la granja.



Figura 5.3. Ubicación de los galpones.

Se compone por un total de cuatro galpones (Figura 5.3) cuyas estructuras se encuentran en buen estado para soportar la instalación de paneles fotovoltaicos, además de que los techos tienen orientación Norte y una inclinación aproximada de 20°. Estos galpones se ubican a más de 100 metros de la acometida eléctrica.

La granja tiene una potencia instalada de 55 kW, de los cuales 35 kW corresponden al sistema de ventilación de los galpones. Se conecta a la red de ENERSA (principal distribuidora de energía de la provincia) a través de una conexión rural T1, por lo que la facturación de energía es bimestral. La información suministrada por el usuario, expuesta en la Tabla 5.1, indica que el consumo tiene carácter estacional, requiriendo más energía durante el verano debido a la necesidad de ventilación en los galpones. Por otro lado, el consumo de energía cae durante los meses templados y es mínimo durante el invierno, debido a la utilización de gas envasado para calefacción.

Bimestre	1	2	3	4	5	6	Anual
Consumo kWh	10411	10179	4384	2744	3151	4022	34891

Tabla 5.1. Consumo de energía bimestral de la granja.

Las granjas avícolas tienen ciclos de funcionamiento dados por el tiempo de cría de las aves, que rondan los 42 días, y el tiempo de descanso de los galpones (período de desinfección), que varía entre 10 y 14 días [137]. Estos ciclos, de duración aproximada de dos meses, impactan sobre la demanda de las granjas, produciendo variaciones periódicas en el consumo.

5.4.3 Evaluación tecno-económica

5.4.3.1 Configuración de HOMER Pro®

- Vida útil del proyecto

La vida útil del proyecto se supone igual a 25 años, en concordancia con la vida útil de los paneles que representan la mayor inversión del proyecto. La vida útil del inversor se estima en 15 años.

- Radiación solar

Los datos promedios de irradiancia horizontal global (GHI), utilizados para modelar la generación de los paneles fotovoltaicos, se obtienen de la base de datos de la NASA, incluida en el software, y a través de la ubicación geográfica del proyecto. El software genera el perfil

anual de irradiancia a partir de valores promedios. Para maximizar la generación de los paneles en la granja, la orientación debe ser norte y con inclinación de 32° [138].




Figura 5.4. Valores promedios diarios mensuales de GHI e índice de nubosidad en Valle María.

- Demanda de las cargas

El perfil anual de demanda se genera a partir de la información de consumo de la Tabla 5.1 y de la reconciliación con perfiles promedios de meses de calor y frío de una granja de la zona. Los perfiles generados se muestran en la Figura 5.5, donde se observa un cambio en el consumo de mes a mes, debido al tiempo de cría de las aves y el tiempo de descanso del galpón mencionado anteriormente.

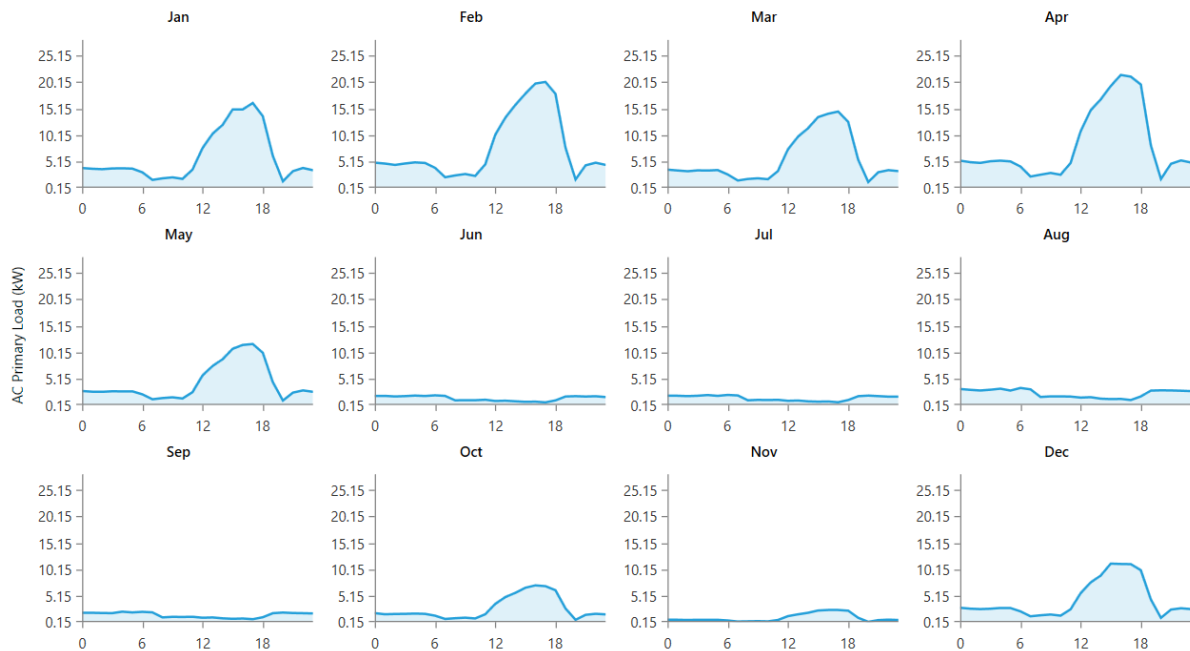


Figura 5.5. Perfiles diarios promedios de cada mes (gráfico obtenido con HOMER Pro®)

- Parámetros económicos

Los parámetros económicos utilizados para el análisis del proyecto corresponden a julio de 2022, momento en el que se llevó a cabo la evaluación. Como moneda se utilizó el dólar

estadounidense y se supuso una inflación anual del 5%. El dólar oficial del Banco Nación en julio de 2022 tenía un valor de \$138. Este cambio es el adoptado por los proveedores en la comercialización de los equipos, por lo que se utilizó para dolarizar el precio de tarifas y costos.

Dado que el proyecto se financia únicamente con fondos propios, la tasa de descuento nominal (i_n) puede considerarse igual al costo de oportunidad (k_c), que normalmente se estima según el modelo CAPM (*capital asset price model*) [135]. Sin embargo, el usuario definió una rentabilidad mínima del 10%, por lo que se consideró $i_n=10\%$.

- Tarifa de energía de ENERSA

Teniendo en cuenta el consumo de energía de la granja, se recomienda el cambio de conexión T1 (demandas pequeñas) a T2 (demandas medianas) para disminuir el costo de facturación. La potencia contratada a la distribuidora, se determina luego a través de simulación.

El cuadro tarifario aplicado se expone en la Tabla 5.2. Se muestran las tarifas aplicadas para el consumo de energía de un usuario T2 y para la inyección a red. La facturación de energía para usuarios T2 es mensual. Su costo total está integrado por un costo de potencia y un costo de energía. El costo de potencia se determina a través de la potencia contratada y la tarifa por kW-mes, mientras que el costo de energía se calcula mediante el consumo total mensual y la tarifa de energía. Además, se adiciona a la factura un costo por transgresión de potencia. Este costo se calcula aplicándole la mitad de la tarifa por potencia a la diferencia entre la potencia registrada y la contratada.

Usuario	Tarifa de potencia		Tarifa de energía	
Consumidor	872.57 \$/kW-mes	6.38 USD/kW-mes	10.3057 \$/kWh	0.074 USD/kWh
Generador	-	-	4.9208 \$/kWh	0.035 USD/kWh

Tabla 5.2. Cuadro tarifario de ENERSA para demandas medianas (T2), vigente desde el 1° de junio al 31 de julio de 2022.

En julio de 2022, el costo de conexión para inyección a red era de \$102980.5, equivalente a USD746.

- Costo de componentes y mano de obra

HOMER Pro® utiliza los costos por unidad de potencia de paneles fotovoltaicos y del inversor para utilizar el optimizador. Promediando el costo por unidad de potencia de paneles

fotovoltaicos e inversores comercializados por la empresa LV Energy en julio de 2022, se adopta 659 USD/kW para paneles fotovoltaicos y 127 USD/kW para inversores.

Según las normativas descritas en 5.4.1, el medidor de la generación debe estar en el pilar de la acometida. Para evitar el elevado costo del cableado subterráneo necesario si los paneles se instalasen en el techo de los galpones, se propone ubicar los paneles sobre tierra y en cercanías al pilar, reutilizando materiales disponibles en la granja para realizar las estructuras.

Costos adicionales como cables, dispositivos de protección y mano de obra se incluyen estimando un 30% adicional sobre el costo por kW de generación fotovoltaica instalada.

- Gestión de la energía

Este caso de estudio representa una MR sencilla con conexión a red, siendo el inversor el único encargado de gestionar la energía en el nivel primario y secundario de la jerarquía de control (Figura 1.1). A diferencia de los inversores que funcionan aislados (como el desarrollado en el apartado 4.4.2.4), los inversores con conexión a red funcionan como fuentes de corriente. Es decir, la tensión en el puente H (ver Figura 4.8) se mantiene constante inyectando más o menos corriente a la red o a la carga. En el caso de los inversores solares, esta corriente inyectada depende de la radiación solar existente y consecuentemente de la potencia de generación disponible.

Dado que la conexión del inversor con la red se da agua abajo del medidor bidireccional y antes de la carga, se considera que la potencia inyectada por el inversor es primero consumida por la carga y el excedente, en caso que hubiese, se inyecta a red. Por contrario, si la generación no es suficiente para abastecer la carga, el déficit se consume de la red. Esta lógica fue implementada en HOMER Pro®.

5.4.3.2 Resultados de la simulación

Se utilizaron los parámetros y configuraciones mencionadas en el apartado 5.4.3.1 para ejecutar la simulación. Los resultados indican que la topología óptima, conforme el criterio (5.3), se compone de 23 kW_p de generación fotovoltaica y un inversor de 18.1 kW nominales.

En base a estos resultados preliminares, se selecciona el inversor y los paneles fotovoltaicos a utilizar, además de la configuración del arreglo de paneles:

- Inversor fotovoltaico *on-grid*

El inversor seleccionado es el GW20KT-DT de la marca GoodWe. Es un inversor trifásico de 20 kW de potencia nominal que incorpora dos MPPTs, con dos entradas cada uno de hasta 1100 V en CC (4 entradas en total). Tiene un costo aproximado de USD 2600.

- Paneles

La instalación fotovoltaica se compone por un total de 72 paneles policristalinos de la marca LV Energy, modelo LVE72PSe, con una potencia nominal de 330 W cada uno (23.76 kW totales). Los paneles certifican normas IEC61215 y IEC61730-1/2. El costo por panel ronda los USD 217.

Teniendo en cuenta la cantidad de entradas y la tensión admitida por el inversor seleccionado, el arreglo de paneles se compone por 4 *strings* (uno por entrada del inversor) de 18 paneles conectados en serie. De esta manera la corriente máxima de cada *string* ronda los 9.3 A (corriente de cortocircuito de un panel) y su tensión máxima es aproximadamente 822 V (45.7 V por panel en circuito abierto). La corriente y la tensión mencionadas se obtienen bajo condiciones estándares (STC), es decir, 1000 W/m², temperatura de la celda igual a 25 °C y masa de aire AM 1.5.

La simulación final incorpora los costos del modelo del inversor y de los paneles seleccionados. Los resultados se exponen en la Tabla 5.3. La topología 1 incluye generación fotovoltaica y conexión con la distribuidora de energía, mientras que la topología 2 considera solo abastecimiento mediante la distribuidora. Se observa que la topología 1 requiere de una inversión inicial de USD23639, teniendo menor NPC y LCOE, siendo este último 41% menor. Además, el retorno de la inversión es de 3.9%, la tasa interna de retorno 6.1% y la amortización en 11 años (vida útil del proyecto supuesto en 25 años).

Topología				Costos				PV		Red	
Nº	Red	PV kW	Inv. kW	LCOE USD	NPC USD	Costo de operación USD/año	Capital inicial USD	Frac. Ren. %	Generación kWh/año	Energía comprada kWh	Energía vendida kWh
1	Si	23.8	20	0.0570	45044	1483	23639	62.8	36274	20348	20725
2	Si	-	-	0.0982	48262	3325	0	0	0	34031	0

Tabla 5.3. Resultados de la simulación de HOMER Pro®.

La producción de la instalación fotovoltaica ronda los 36274 kWh anuales, de los cuales 20725 se venden a red, 13683 se consumen en la carga y 1866 se disipan en pérdidas. Como resultado, el 37% de la generación fotovoltaica es consumido en la carga. La fracción renovable, que indica la participación de la generación fotovoltaica sobre el consumo de la granja y la venta a la red, es del 62.8%.

La Figura 5.6 muestra la potencia promedio generada por los paneles fotovoltaicos y la potencia promedio absorbida por la red en cada mes. La demanda a red durante los meses de invierno es muy baja, siendo preponderante la generación fotovoltaica y consecuentemente inyectando más energía de la que se compra.




Figura 5.6. Generación promedio mensual.

5.5 Instalación y puesta en marcha

El procedimiento realizado para conectar la instalación en paralelo con la red de distribución de ENERSA fue el siguiente:

- Solicitud de cambio de conexión T1 a T2.
- Solicitud de factibilidad para conectar 24 kW_p de generación fotovoltaica a la red de distribución en el punto de conexión de la granja.
- Solicitud de conexión de un pequeño usuario generador a la red.
- Presentación del plano unifilar de la instalación.
- Presentación de memoria técnica y datos técnicos del inversor y los paneles fotovoltaicos.
- Presentación de cumplimiento de requisitos técnicos.
- Finalmente, el 1º de febrero de 2023 la instalación se conectó a la red de ENERSA y se obtuvo el Acta de Habilitación emitido por la distribuidora.

Una vez aprobada la factibilidad de conexión por parte de la distribuidora, se gestionó la compra directa de los equipos en LV Energy (fabricante nacional de paneles fotovoltaicos e importador de tecnología asociada).

5.5.1 Circuito eléctrico

5.5.1.1 Protecciones

Los circuitos de continua y de alterna del inversor deben contar con dispositivos de protección, según los requisitos expuestos en el apartado 5.4.1. Se dispusieron dos tableros,

uno para cada circuito del inversor. Adicionalmente, se ubica un segundo tablero de alterna para la micro-generación ubicado en el pilar, de modo de poder desenergizar el conductor que une el inversor con la red, desde ambos extremos. La Tabla 5.4 expone las protecciones seleccionadas.

Dispositivo de protección	Tableros del inversor				Tablero del pilar	
	DC		AC		AC	
	Cantidad	Característica	Cantidad	Característica	Cantidad	Característica
Descargador gaseoso	4	20 kVA y 1000 V, tipo II, bipolares.	4	20 kA y 275 Vac, unipolares.	-	-
Térmica / termomagnética	2 (una por MPPT)	20 A y 1000 V, de 4 polos	1	Tetrapolar de 40 A	1	Tetrapolar de 40 A
Interruptor diferencial	-	-	1	Tetrapolar de 300 mA y 63 A	1	Tetrapolar de 300 mA y 63 A.

Tabla 5.4. Dispositivos de protección en cada tablero.

5.5.1.2 Diagrama unifilar

La Figura 5.7 muestra el diagrama unifilar de la micro-generación con las protecciones mencionadas anteriormente. La puesta a tierra se realiza a través de una jabalina individual, independiente de la puesta a tierra de la instalación de la granja.




Figura 5.7. Diagrama unifilar de la micro-generación.

5.5.2 Configuración del inversor

La distribuidora de energía emite el Acta de Habilitación luego de realizar una serie de ensayos de seguridad sobre desconexión y reconexión automática, según la Resolución 168/20

del EPRE. En base a la resolución, el inversor se configuró con los siguientes parámetros, utilizando la App SolarGo:

- Protección anti-isla: 0.2 s de tiempo de desconexión frente a ausencia de tensión en la red.
- Reconexión automática: tiempo de reconexión del inversor en 3.5 minutos, luego de reestablecidos los valores de tensión y frecuencia de la red.
- Protección de tensión: desconexión para tensión mayor a 242 V y tensión menor a 202 V. Tiempo de desconexión: 0.2 s.
- Protección de frecuencia: desconexión para frecuencia mayor a 51 Hz y frecuencia menor a 49 V. Tiempo de desconexión: 0.2 s.

5.5.3 Estructura

La estructura se diseña para que los paneles fotovoltaicos tengan una inclinación aproximada de 32° , con orientación norte. Los paneles de cada *string* se disponen sobre dos de perfiles C galvanizados (de 10x5 cm y 1.5 mm de espesor), como se ve en la Figura 5.11. Estos perfiles se montan sobre pilotines de hormigón (en la parte frontal de la estructura), y sobre caños petrolero de 10 cm de diámetro (en la parte posterior de la estructura). Tanto los pilotines como los caños se entierran 60 cm y se cubre con hormigón. Los paneles se sujetan a los perfiles C a través de perfiles omega de aluminio y bulones.

5.5.4 Fotos de la micro-generación



Figura 5.8. Disposición de los cuatro *strings* de paneles.



Figura 5.9. Gabinete del inversor y de los tableros de protección.




Figura 5.10. Tablero de protección de CC (izquierda) y AC (derecha).



Figura 5.11. Estructura de soporte de los paneles y gabinete del inversor.

5.5.5 Resultados de la instalación

La Tabla 5.5 resumen los datos obtenidos de la micro-generación para el período comprendido entre el 1° de febrero de 2023 hasta el 1° de febrero de 2024.

El mayor consumo tuvo lugar en enero de 2024, coincidente con la mayor generación fotovoltaica, ya que el 78% de la generación renovable fue absorbida por las cargas de la granja. Sin embargo, enero fue el mes donde la energía renovable tuvo menor preponderancia en el consumo de la carga, con 17%. Durante febrero de 2023, la granja no funcionó a plena capacidad por mantenimiento de los galpones por lo que su consumo fue bajo. En los meses con bajo consumo, el porcentaje de renovable en la carga es mayor.

Instalación	Variable	Mes												
		Feb.	Mar.	Abr.	May.	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.	Ene.	Total
Granja	Consumo total (kWh)	1088	7364	3115	1394	1944	545	1676	1109	1951	5956	1870	15226	43238
	Consumo de red (kWh)	697	5659	2322	895	1470	361	1147	785	1376	4781	1292	12610	33395
	Consumo de PV (kWh)	391	1705	793	499	474	184	529	324	575	1175	578	2616	9843
	Renovable en carga (%)	36	23	25	36	24	34	32	29	29	20	31	17	22
	Demanda pico sin micro-generación (kW)	40	42	41	11	40	10	41	42	41	48	48	49	37
Micro-generación	Demanda pico con micro-generación (kW)	23	42	41	11	33	4	34	38	41	48	40	45	33
	Generación total (kWh)	3316	3512	3140	2595	1958	2026	3134	2982	3452	3101	3084	3358	35658
	Inyección a red (kWh)	2925	1807	2347	2096	1484	1842	2605	2658	2877	1926	2506	742	25815
	Renovable a carga (%)	12	49	25	19	24	9	17	11	17	38	19	78	27

Tabla 5.5. Datos del funcionamiento de la micro-generación (período de 1/02/2023-01/11/2023)

En general, se concluye que el 22% de la energía total consumida por la granja fue abastecida por los paneles solares y que el 27% de la generación renovable producida fue absorbida por la carga, inferior al 37% estimado con HOMER Pro®. Esto puede atribuirse principalmente a la diferencia entre el perfil de demanda creado y el perfil real del período evaluado, de modo que la correlación entre generación y demanda fue menor a la esperada. En este sentido, los meses con mayor consumo de energía de la granja presentan mayor correlación (marzo y enero), siendo mayor la energía renovable a carga. La generación fotovoltaica representó el 82% del consumo de la granja para el período evaluado.




Figura 5.12. Potencia promedio de la demanda consumo de la granja y de la generación fotovoltaica.

En la Figura 5.12 se indica gráficamente los datos reales de demanda y generación promedio de la granja, para el período mencionado, comparable con la Figura 5.6 asociada a los promedios obtenidos mediante simulación. De la comparación de los gráficos, se observa correlación en la generación fotovoltaica, pero se evidencia la diferencia entre el perfil de demanda supuesto en la simulación y el real para el período evaluado. Se evidencia que la granja tuvo un consumo notablemente mayor al año anterior, particularmente durante el mes de enero de 2024. Se observa además el patrón oscilatorio bimestral de su consumo, dado por el tiempo de cría y descanso de los galpones.

La Tabla 5.6 resume los costos de la factura de electricidad de la granja luego de incorporar micro-generación (T2 con PV), pero además muestra los resultados de dos casos hipotéticos adicionales: 1) la granja conectada a la red sin micro-generación (caso base, T2), y 2) la granja conectada a la red con micro-generación, pero además incluyendo una gestión de energía ideal (T2 con PV y gestión). Dicha gestión considera que toda la energía producida por los paneles es consumida por las cargas de la granja y que solo se inyecta a red en caso que la generación

sea mayor a la demanda. Además, la gestión nunca permite que la potencia registrada sea mayor a la contratada, evitando costos adicionales por transgresión de potencia.

Estos casos se evalúan teniendo en cuenta los consumos y generaciones mensuales de la Tabla 5.5, y la tarifa de ENERSA prevista para marzo de 2024. Los costos de facturación incluyen impuestos y percepciones, y se expresan en dólares estadounidenses, utilizando como cambio el precio de venta del Banco Nación en febrero de 2024 (\$853 equivalente a USD1).

Conexión	Facturación mensual (USD)												
	Feb.	Mar.	Abr.	May.	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.	Ene.	Tot.
T2	645	1486	922	382	755	272	736	678	771	1534	867	2869	11916
T2 con PV	180	1169	693	205	509	150	451	433	543	1140	537	2170	8178
T2 con PV y gestión	82	699	200	147	201	122	123	101	121	571	137	1736	4240

Tabla 5.6. Factura de energía para conexión T2, T2 con micro-generación y T2 con micro-generación y gestión de energía.

Se observa que la incorporación de generación fotovoltaica brindó un ahorro anual de USD3738 respecto al caso base (T2). Se observa también que una gestión ideal de la energía podría brindar un ahorro de USD7676 respecto al caso base y de USD3938 respecto al mismo caso, pero sin gestión.

5.6 Discusión

Se presentó el desarrollo completo de un proyecto de 24 kW_p de generación fotovoltaica conectado a la red, exponiendo cada etapa, desde el dimensionamiento de los componentes hasta la puesta en marcha. El proyecto se llevó a cabo en una granja avícola de Entre Ríos, que representa un caso de interés regional dada la gran importancia de esta industria en la provincia. Además, se analizó el desempeño de la generación para el período anual comprendido entre el 1° de febrero de 2023 al 1° de febrero del 2024.

En el período evaluado, la generación fotovoltaica brindó una reducción anual de USD3738 en la factura eléctrica respecto a la misma conexión sin generación (caso base, conexión T2), equivalente a una reducción del 31% (utilizando el cuadro tarifario vigente en marzo de 2024). Durante el mismo período ha generado 35658 kWh, de los cuales 25815 kWh fueron inyectados a la red. Esto implica que el 73% de la generación fotovoltaica fue inyectada a red, o lo que es equivalente, el 27% de la generación fue consumida en la carga.

En este sentido, dada la relación costo de compra/precio de venta de energía (más impuestos gravados sobre el consumo), la minimización de energía inyectada a red y la restricción de demanda registrada menor o igual a la contratada puede brindar grandes beneficios. Por este motivo, se planteó un caso hipotético ideal donde toda la energía generada se consume en la granja y solo se vende a red si la generación supera a la carga, además de mantener la demanda siempre inferior a la potencia contratada. Este caso ofrece una disminución anual en la factura de USD3938 respecto a la micro-generación y USD7676 respecto al caso base, lo que demuestra la importancia de una correcta gestión. Esto quiere decir que la implementación de estrategias de gestión de la demanda puede aumentar los beneficios económicos, disminuir la inversión inicial y el tiempo de amortización. En este sentido, estrategias como conservación energética, corrimiento de carga o recorte de pico pueden ser aplicadas en bombas de agua, en ventilación y/o adicionando alguna forma de almacenamiento de energía.

Como conclusión final, el análisis del caso muestra la potencialidad del desarrollo de MRs en granjas avícolas por lo siguiente:

- Incorporación de nuevas tecnologías en las granjas que permiten desarrollar estrategias de gestión de la demanda para aumentar el consumo de generación renovable.
- Importancia de la industria avícola en Entre Ríos.
- Correlación existente entre consumo y generación fotovoltaicas en las granjas, particularmente en períodos de alta temperatura y consumo.
- Contexto de sinceramiento de tarifas de energía y un nuevo marco legal provincial que busca fomentar la generación a partir de recursos renovables.

Capítulo 6

CONCLUSIONES Y TRABAJOS FUTUROS

6.1 Conclusiones

En esta Tesis se abordaron diferentes estrategias que contribuyen a mejorar la operación y el desempeño de las microrredes con y sin conexión a la red de distribución. Los esquemas de gestión de la energía se abordaron desde el nivel terciario de la jerarquía de control utilizando distintos marcos de control predictivo para desarrollar estrategias de despacho de generadores y de gestión de la demanda.

El control predictivo basado en modelo posee características ideales para su utilización en esquemas de gestión energética ya que su funcionamiento se basa en la resolución de un problema de optimización, de ventana temporal deslizable, en el que pueden incluirse restricciones físicas/operativas, modelos del sistema y modelos de predicciones. Los sistemas con capacidad de almacenamiento térmico o eléctrico brindan al controlador la posibilidad de desplazar temporalmente su operación de manera de cumplir con las restricciones impuestas y minimizar una función costo asociada. Los esquemas de gestión de energía desarrollados se basan en este principio; en el Capítulo 2, el control desplaza y modifica la operación del sistema de climatización para maximizar el confort térmico y disminuir la factura eléctrica, mientras que en el Capítulo 3, el control adiciona a la gestión de la climatización, el desplazamiento y control de la carga/descarga de baterías. En este último caso, el funcionamiento sinérgico del sistema climatización-baterías, bajo un mismo controlador, ofrece grandes mejoras en términos de uso eficiente de la energía.

En cuanto a los sistemas de protección de fallas, el método del Capítulo 4 posee características que facilitan su implementación práctica dado su bajo costo computacional. Para la detección, identificación y localización de la falla solo requiere de mediciones de tensión y corriente en las cargas y convertidores, a diferencia de otros esquemas encontrados en la literatura que necesitan mediciones adicionales en los buses de conexión. De esta manera se reduce la cantidad de nodos de comunicación con la central de cómputo. En cuanto a la aislación de fallas, la central de cómputo envía las señales de apertura a los *circuit breakers* a través de las mismas líneas de alimentación de la microrred por lo que se evita la necesidad de canales de comunicación adicionales.

Por otro lado, el nuevo marco legal de Entre Ríos busca fomentar la GR y la GD. En este sentido, la instalación de 24 kW_p de generación fotovoltaica, descrita en el Capítulo 5, fue una de las primeras conexiones que se realizaron a la red de la distribuidora provincial para ese nivel de potencia. En cuanto a la metodología, la utilización del software HOMER Pro® facilita la etapa de dimensionamiento y simulación tecno-económica, pudiendo verificarse los valores calculados en la práctica, luego de conectarse a la red. Por otro lado, este caso de estudio muestra los beneficios económicos sustanciales que podrían obtenerse si se gestionara la energía. Podrían incluirse estrategias de gestión de la demanda y/o utilizar dispositivos de almacenamiento, de manera de consumir la máxima cantidad de energía renovable en las cargas y controlar los picos de demanda a red.

6.2 Trabajos futuros

A partir las investigaciones realizadas durante el desarrollo de la Tesis, y en base a los desafíos actuales, surgen las siguientes líneas de investigación:

- **Evaluación de los esquemas propuestos en una microrred piloto:** se pretende evaluar la estrategia de gestión energética desarrollada en el Capítulo 3, asociada al Caso 1, con funcionamiento aislado. También evaluar el sistema de protección para el caso de estudio abordado en el Capítulo 4, ambos basados en topologías similares. Se prevé ensayar el método de protección del Capítulo 4 en la microrred DC piloto del *Energy Systems Research Laboratory de la Florida International University*, en Miami, donde se realizó una estadía de investigación durante el año 2023. La microrred tiene la misma topología que la mostrada en la Figura 4.3, por lo que se espera poder validar empíricamente el funcionamiento del esquema propuesto. Además, se desea mejorar la metodología de detección de las fallas cambiando el criterio diferencial utilizado por la implementación de cartas de control, que ofrecen mayor sensibilidad. Por otro lado, se plantea continuar con la construcción de un modelo observador para las cargas, de manera de evitar la medición de corriente y tensión en ellas, lo que mejoraría su implementación desde un punto de vista práctico, ya que de ser posible solo requeriría de las mediciones de los convertidores. Además, se dispone de las instalaciones de la granja avícola expuesta en el Capítulo 5 para implementar tecnología y estrategias de gestión energética, dado los potenciales beneficios económicos analizados.

- **Gestión de la energía y sistemas de protección en esquemas multi-microrredes:** se trata de uno de los principales desafíos científicos actuales en referencia a microrredes. Se pretende gestionar de manera óptima el flujo de potencia entre dos o más microrredes conforme criterios que incluyen estabilidad de los sistemas, utilización óptima de los recursos y abastecimiento de cargas compartidas. Además, se busca integrar los sistemas de protección con la gestión de la energía de manera de mitigar las fallas y mejorar la resiliencia.
- **Microrredes con integración de energía renovable para estaciones de carga de vehículos eléctricos:** otro de los desafíos energéticos actuales es el abastecimiento de los vehículos eléctricos para su utilización de manera masiva, ya que la carga de sus baterías implica un gran impacto sobre la red de distribución en términos de potencia y energía. El desarrollo de microrredes con integración de energía renovable utilizadas como estaciones de carga puede ser una solución sustentable y de menor impacto en la red.

Bibliografía

- [1] C. Bordons, F. García-Torres, y L. Valverde, “Gestión Óptima de la Energía en Microrredes con Generación Renovable”, *Revista Iberoamericana de Automática e Informática Industrial RIAI*, vol. 12, n° 2, pp. 117–132, abr. 2015, doi: 10.1016/j.riai.2015.03.001.
- [2] “IEEE Guide for Design, Operation, and Integration of Distributed Resource Island Systems with Electric Power Systems”, IEEE. doi: 10.1109/IEEESTD.2011.5960751.
- [3] S. Chowdhury, S. P. Chowdhury, y P. Crossley, *Microgrids and active distribution networks*. en IET renewable energy series, no. 6. Stevenage: Institution of Engineering and Technology, 2009.
- [4] C. Bordons, F. Garcia-Torres, y M. A. Ridao, *Model Predictive Control of Microgrids*. en Advances in Industrial Control. Cham: Springer International Publishing, 2020. doi: 10.1007/978-3-030-24570-2.
- [5] D. Mariano-Hernández, L. Hernández-Callejo, A. Zorita, O. Duque, y F. Santos Garcia, “A review of strategies for building energy management system: Model predictive control, demand side management, optimization, and fault detect & diagnosis”, *Journal of Building Engineering*, vol. 33, p. 101692, jul. 2020, doi: 10.1016/j.job.2020.101692.
- [6] D. E. Olivares, A. Mehrizi-Sani, A. Etemadi, C. Cañizares, A. Iravani, M. Kazerani, A. Hajimiragha, O. Gomis-Bellmunt, M. Saadifard, R. Palma-Behnke, G. Jiménez-Estévez and N. Hatziargyriou, “Trends in Microgrid Control”, *IEEE Transactions on Smart Grid*, vol. 5, n° 4, pp. 1905–1919, jul. 2014, doi: 10.1109/TSG.2013.2295514.
- [7] K. De Brabandere, K. Vanthournout, J. Driesen, G. Deconinck, y R. Belmans, “Control of Microgrids”, en *2007 IEEE Power Engineering Society General Meeting*, jun. 2007, pp. 1–7. doi: 10.1109/PES.2007.386042.
- [8] C. Bordons, F. Garcia-Torres, y M. A. Ridao, *Model Predictive Control of Microgrids*. en Advances in Industrial Control. Cham: Springer International Publishing, 2020. doi: 10.1007/978-3-030-24570-2.
- [9] J. C. Vasquez, J. M. Guerrero, J. Miret, M. Castilla, y L. G. de Vicuña, “Hierarchical Control of Intelligent Microgrids”, *IEEE Industrial Electronics Magazine*, vol. 4, n° 4, pp. 23–29, dic. 2010, doi: 10.1109/MIE.2010.938720.
- [10] D. Ipsakis, S. Voutetakis, P. Seferlis, F. Stergiopoulos, S. Papadopoulou, y C. Elmasides, “The effect of the hysteresis band on power management strategies in a stand-alone power system”, *Energy*, vol. 33, n° 10, pp. 1537–1550, oct. 2008, doi: 10.1016/j.energy.2008.07.012.
- [11] E. Kuznetsova, Y.-F. Li, C. Ruiz, E. Zio, G. Ault, y K. Bell, “Reinforcement learning for microgrid energy management”, *Energy*, vol. 59, pp. 133–146, sep. 2013, doi: 10.1016/j.energy.2013.05.060.
- [12] Y. Ji, J. Wang, J. Xu, X. Fang, y H. Zhang, “Real-Time Energy Management of a Microgrid Using Deep Reinforcement Learning”, *Energies*, vol. 12, n° 12, p. 2291, jun. 2019, doi: 10.3390/en12122291.
- [13] B. Zhu, H. Tazvinga, y X. Xia, “Model Predictive Control for Energy Dispatch of a Photovoltaic-Diesel-Battery Hybrid Power System”, *IFAC Proceedings Volumes*, vol. 47, n° 3, pp. 11135–11140, 2014, doi: 10.3182/20140824-6-ZA-1003.00943.
- [14] J. Hu, Y. Xu, K. W. Cheng, y J. M. Guerrero, “A model predictive control strategy of PV-Battery microgrid under variable power generations and load conditions”, *Applied Energy*, vol. 221, pp. 195–203, jul. 2018, doi: 10.1016/j.apenergy.2018.03.085.

- [15] F. Baharudin, N. Mohd Adlan, J. Kassim, N. Hamzah y S. Ghazali, “Effect of Heating, Ventilation, and Air Conditioning (HVAC) System on Indoor Air Quality in a Medical Facility”, *JSCET*, vol. 2, n° 2, pp. 80–90, sep. 2023, doi: 10.24191/jscet.v2i2.80-90.
- [16] S. Saran, M. Gurjar, A. Baronia, V. Sivapurapu, P. Ghosh, G. Raju and I. Maurya, “Heating, ventilation and air conditioning (HVAC) in intensive care unit”, *Crit Care*, vol. 24, n° 1, p. 194, dic. 2020, doi: 10.1186/s13054-020-02907-5.
- [17] S. J. Hoff, “HVAC Techniques for Modern Livestock and Poultry Production Systems”, en *HVAC System*, M. S. Kandelousi, Ed., InTech, 2018. doi: 10.5772/intechopen.78785.
- [18] G. Ramos Ruiz, E. Lucas Segarra, y C. Fernández Bandera, “Model predictive control optimization via genetic algorithm using a detailed building energy model”, *Energies*, vol. 12, n° 1, p. 34, 2018.
- [19] J. Hossain, A. Kadir, A. Hanafi, H. Shareef, T. Khatib, K. Baharin y M. Sulaima, “A Review on Optimal Energy Management in Commercial Buildings”, *Energies*, vol. 16, n° 4, p. 1609, feb. 2023, doi: 10.3390/en16041609.
- [20] G. Strbac, “Demand side management: Benefits and challenges”, *Energy Policy*, vol. 36, n° 12, pp. 4419–4426, dic. 2008, doi: 10.1016/j.enpol.2008.09.030.
- [21] “The impact of demand side management strategies in the penetration of renewable electricity - ScienceDirect”. Accedido: 26 de junio de 2020. [En línea]. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0360544211003902>
- [22] A. T. Dahiru, D. Daud, C. W. Tan, Z. T. Jagun, S. Samsudin, y A. M. Dobi, “A comprehensive review of demand side management in distributed grids based on real estate perspectives”, *Environ Sci Pollut Res*, ene. 2023, doi: 10.1007/s11356-023-25146-x.
- [23] Y. M. Lee, R. Horesh, y L. Liberti, “Optimal HVAC Control as Demand Response with On-site Energy Storage and Generation System”, *Energy Procedia*, vol. 78, pp. 2106–2111, nov. 2015, doi: 10.1016/j.egypro.2015.11.253.
- [24] B. Woo-Shem, K. Pattawi, H. Covington, P. McCurdy, C. Wang, T. Roth, C. Nguyen, Y. Liu and H. Lee, “Comparing economic benefits of HVAC control strategies in grid-interactive residential buildings”, *Energy and Buildings*, vol. 286, p. 112937, may 2023, doi: 10.1016/j.enbuild.2023.112937.
- [25] A. Franco, E. Crisostomi, y G. Lamberti, “HVAC Systems Control Based on CO2 Monitoring for Reducing Energy Use for Ventilation in Public Buildings After COVID-19 Pandemic”. Rochester, NY, 15 de septiembre de 2022. doi: 10.2139/ssrn.4203406.
- [26] X. Wang y X. Zhang, “HVAC system dynamic management in communities via an aggregation–disaggregation framework”, *International Journal of Electrical Power & Energy Systems*, vol. 142, p. 108207, nov. 2022, doi: 10.1016/j.ijepes.2022.108207.
- [27] S. A. M. Javadian, M.-R. Haghifam, M. Fotuhi Firoozabad, y S. M. T. Bathae, “Analysis of protection system’s risk in distribution networks with DG”, *International Journal of Electrical Power & Energy Systems*, vol. 44, n° 1, pp. 688–695, ene. 2013, doi: 10.1016/j.ijepes.2012.08.034.
- [28] N. Hussain, M. Nasir, J. C. Vasquez, y J. M. Guerrero, “Recent Developments and Challenges on AC Microgrids Fault Detection and Protection Systems—A Review”, *Energies*, vol. 13, n° 9, Art. n° 9, may 2020, doi: 10.3390/en13092149.
- [29] M. E. Baran y I. El-Markaby, “Fault analysis on distribution feeders with distributed generators”, *IEEE Transactions on Power Systems*, vol. 20, n° 4, pp. 1757–1764, nov. 2005, doi: 10.1109/TPWRS.2005.857940.
- [30] S. I. Gkavanoudis, D. Tampakis, K. Malamaki, G. Kryonidis, E. Kontis, K. Ourelidis, J. Maza-Ortega and C. Demoulias, “Protection philosophy in low short-circuit capacity distribution grids with high penetration of converter-interfaced distributed renewable

- energy sources”, *IET gener. transm. distrib.*, vol. 14, n° 22, pp. 4978–4988, nov. 2020, doi: 10.1049/iet-gtd.2020.0714.
- [31] M. A. U. Khan, Q. Hong, A. Egea-Álvarez, A. Dyško, y C. Booth, “A communication-free active unit protection scheme for inverter dominated islanded microgrids”, *International Journal of Electrical Power & Energy Systems*, vol. 142, p. 108125, nov. 2022, doi: 10.1016/j.ijepes.2022.108125.
- [32] “Buildings”, *International Energy Agency (IEA)*, julio de 2023. Accedido: 23 de abril de 2024. [En línea]. Disponible en: <https://www.iea.org/energy-system/buildings>
- [33] Q. Chen, N. Li, y W. Feng, “Model predictive control optimization for rapid response and energy efficiency based on the state-space model of a radiant floor heating system”, *Energy and Buildings*, vol. 238, p. 110832, may 2021, doi: 10.1016/j.enbuild.2021.110832.
- [34] Z. Zhang, A. Chong, Y. Pan, C. Zhang, y K. P. Lam, “Whole building energy model for HVAC optimal control: A practical framework based on deep reinforcement learning”, *Energy and Buildings*, vol. 199, pp. 472–490, 2019.
- [35] L. Li, Y. Fu, J. C. Fung, H. Qu, y A. K. Lau, “Development of a back-propagation neural network and adaptive grey wolf optimizer algorithm for thermal comfort and energy consumption prediction and optimization”, *Energy and Buildings*, vol. 253, p. 111439, 2021.
- [36] S. Papantoniou, D. Kolokotsa, y K. Kalaitzakis, “Building optimization and control algorithms implemented in existing BEMS using a web based energy management and control system”, *Energy and Buildings*, vol. 98, pp. 45–55, 2015.
- [37] Q. Zhao, Z. Lian, y D. Lai, “Thermal comfort models and their developments: A review”, *Energy and Built Environment*, vol. 2, n° 1, pp. 21–33, ene. 2021, doi: 10.1016/j.enbenv.2020.05.007.
- [38] L. Gelazanskas y K. A. A. Gamage, “Demand side management in smart grid: A review and proposals for future direction”, *Sustainable Cities and Society*, vol. 11, pp. 22–30, feb. 2014, doi: 10.1016/j.scs.2013.11.001.
- [39] G. Morales-España, R. Martínez-Gordón, y J. Sijm, “Classifying and modelling demand response in power systems”, *Energy*, vol. 242, p. 122544, mar. 2022, doi: 10.1016/j.energy.2021.122544.
- [40] F. Yuan, R. Yao, S. Sadrizadeh, B. Li, G. Cao, S. Zhang, S. Zhou, H. Liu, A. Bogdan, C. Croitoru, A. Melikov, C. Short and B. Li, “Thermal comfort in hospital buildings – A literature review”, *Journal of Building Engineering*, vol. 45, p. 103463, ene. 2022, doi: 10.1016/j.jobbe.2021.103463.
- [41] A. A. Gatea, M. F. M. Batcha, y J. Taweekun, “Energy Efficiency and Thermal Comfort in Hospital Buildings: A Review”, vol. 12, n° 3, 2020.
- [42] S. N. Bragagnolo, R. M. Schierloh, J. R. Vega, y J. C. Vaschetti, “Demand response strategy applied to planning the operation of an air conditioning system. Application to a medical center”, *Journal of Building Engineering*, vol. 57, p. 104927, 2022.
- [43] E. Khanmirza, A. Esmailzadeh, y A. H. D. Markazi, “Design and experimental evaluation of model predictive control vs. intelligent methods for domestic heating systems”, *Energy and Buildings*, vol. 150, pp. 52–70, 2017.
- [44] A. L. A. da Fonseca, K. M. S. Chvatal, y R. A. S. Fernandes, “Thermal comfort maintenance in demand response programs: A critical review”, *Renewable and Sustainable Energy Reviews*, vol. 141, p. 110847, may 2021, doi: 10.1016/j.rser.2021.110847.
- [45] G. Serale, M. Fiorentini, A. Capozzoli, D. Bernardini, y A. Bemporad, “Model Predictive Control (MPC) for Enhancing Building and HVAC System Energy Efficiency: Problem Formulation, Applications and Opportunities”, *Energies*, vol. 11, n° 3, Art. n° 3, mar. 2018, doi: 10.3390/en11030631.

- [46] A. Baniasadi, D. Habibi, O. Bass, y M. A. S. Masoum, “Optimal Real-Time Residential Thermal Energy Management for Peak-Load Shifting With Experimental Verification”, *IEEE Trans. Smart Grid*, vol. 10, n° 5, Art. n° 5, sep. 2019, doi: 10.1109/TSG.2018.2887232.
- [47] B. Pandey, B. Bohara, R. Pungaliya, S. C. Patwardhan, y R. Banerjee, “A thermal comfort-driven model predictive controller for residential split air conditioner”, *Journal of Building Engineering*, vol. 42, p. 102513, oct. 2021, doi: 10.1016/j.jobe.2021.102513.
- [48] S. Seal, B. Boulet, y V. R. Dehkordi, “Centralized model predictive control strategy for thermal comfort and residential energy management”, *Energy*, vol. 212, p. 118456, dic. 2020, doi: 10.1016/j.energy.2020.118456.
- [49] E. Biyik y A. Kahraman, “A predictive control strategy for optimal management of peak load, thermal comfort, energy storage and renewables in multi-zone buildings”, *Journal of Building Engineering*, vol. 25, p. 100826, sep. 2019, doi: 10.1016/j.jobe.2019.100826.
- [50] T. Naseem, A. Javed, M. Humayun y M. Jawad, “Design of an EnergyPlus Model-Based Smart Controller for Maintaining Thermal Comfortable Environment in Non-Domestic Building”, *IEEE Access*, vol. 11, pp. 33134–33147, 2023.
- [51] J. Zhao, K. P. Lam, y B. E. Ydstie, “EnergyPlus model-based predictive control (EPMPC) by using MATLAB/SIMULINK and MLE+”, 2013.
- [52] X. Li y A. Malkawi, “Multi-objective optimization for thermal mass model predictive control in small and medium size commercial buildings under summer weather conditions”, *Energy*, vol. 112, pp. 1194–1206, oct. 2016, doi: 10.1016/j.energy.2016.07.021.
- [53] C. D. Corbin y G. P. Henze, “Predictive control of residential HVAC and its impact on the grid. Part I: simulation framework and models”, *Journal of Building Performance Simulation*, vol. 10, n° 3, pp. 294–312, may 2017, doi: 10.1080/19401493.2016.1231220.
- [54] Y. Yao y D. K. Shekhar, “State of the art review on model predictive control (MPC) in Heating Ventilation and Air-conditioning (HVAC) field”, *Building and Environment*, vol. 200, p. 107952, ago. 2021, doi: 10.1016/j.buildenv.2021.107952.
- [55] M. Ifland, N. Exner, y D. Westermann, “Appliance of Direct and Indirect Demand Side Management”, en *IEEE 2011 EnergyTech*, may 2011, pp. 1–6. doi: 10.1109/EnergyTech.2011.5948534.
- [56] C. W. Gellings, “The concept of demand-side management for electric utilities”, *Proceedings of the IEEE*, vol. 73, n° 10, Art. n° 10, 1985.
- [57] A. R. S. Vidal, L. A. A. Jacobs, y L. S. Batista, “An evolutionary approach for the demand side management optimization in smart grid”, en *2014 IEEE Symposium on Computational Intelligence Applications in Smart Grid (CIASG)*, dic. 2014, pp. 1–7. doi: 10.1109/CIASG.2014.7011561.
- [58] International Standard Organization, “ISO 7730 (2005): Ergonomics of the thermal environment – analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria”. 2005.
- [59] M. Langner, K. Scherber, y W. R. Endlicher, *Indoor heat stress: An assessment of human bioclimate using the UTCI in different buildings in Berlin*, 144^a ed. DE: Gesellschaft für Erdkunde zu Berlin, 2014. Accedido: 28 de mayo de 2022. [En línea]. Disponible en: <https://doi.org/10.12854/erde-144-18>
- [60] O. Kaynakli y M. Kilic, “Investigation of indoor thermal comfort under transient conditions”, *Building and Environment*, vol. 40, n° 2, pp. 165–174, feb. 2005, doi: 10.1016/j.buildenv.2004.05.010.
- [61] S. Godbole, *Investigating the Relationship Between Mean Radiant Temperature (MRT) and Predicted Mean Vote (PMV): A Case Study in a University building*. 2018.

- [62] A. Thavlov y H. W. Bindner, “Thermal models for intelligent heating of buildings”, presentado en 4th International Conference on Applied Energy (ICAE 2012): Energy innovations for a sustainable world, 2012.
- [63] P. Bahramnia, S. M. Hosseini Rostami, J. Wang, y G. Kim, “Modeling and Controlling of Temperature and Humidity in Building Heating, Ventilating, and Air Conditioning System Using Model Predictive Control”, *Energies*, vol. 12, n° 24, p. 4805, dic. 2019, doi: 10.3390/en12244805.
- [64] E. F. Camacho y C. Bordons, *Model predictive control. Advanced textbooks in control and signal processing*. en *Advanced Textbooks in Control and Signal Processing*. London: Springer London, 2004. doi: 10.1007/978-0-85729-398-5_12.
- [65] C. Bordons, F. Garcia-Torres, y M. A. Ridao, *Model predictive control of microgrids*, vol. 358. Springer, 2020.
- [66] V. Bagyaveereswaran, T. D. Mathur, S. Gupta, y P. Arulmozhivarman, “Performance comparison of next generation controller and MPC in real time for a SISO process with low cost DAQ unit”, *Alexandria Engineering Journal*, vol. 55, n° 3, pp. 2515–2524, sep. 2016, doi: 10.1016/j.aej.2016.07.028.
- [67] R. M. Schierloh, J. R. Vega, F. M. Vincitorio, y J. L. Godoy, “Control Predictivo Conjunto del Despacho de Generación Híbrida y de la Demanda Incluyendo Climatización en Microrredes”, en *2020 Argentine Conference, IEEE ARGENCON*, 2020.
- [68] P. A. Hohne, K. Kusakana, y B. P. Numbi, “Improving Energy Efficiency of Thermal Processes in Healthcare Institutions: A Review on the Latest Sustainable Energy Management Strategies”, *Energies*, vol. 13, n° 3, p. 569, ene. 2020, doi: 10.3390/en13030569.
- [69] ENERSA, “Situación Tarifaria”. Accedido: 28 de enero de 2022. [En línea]. Disponible en: <https://www.enersa.com.ar/informacion-comercial/>
- [70] EPRE, “Resolución N° 168/16 Anexo I: Régimen Tarifario”. 2016. [En línea]. Disponible en: http://epre.gov.ar/web/wp-content/uploads/2016/11/Resolucion-168-16_A-I.pdf
- [71] *Ley 27191 Régimen de Fomento Nacional para el uso de Fuentes Renovables de Energía destinada a la Producción de Energía Eléctrica. Modificación*. [En línea]. Disponible en: <https://servicios.infoleg.gob.ar/infolegInternet/anexos/250000-254999/253626/norma.htm>
- [72] Norma IRAM 11601, “Acondicionamiento térmico de edificios. Métodos de cálculo”. 1996.
- [73] R. Riemer y A. Shapiro, “Biomechanical energy harvesting from human motion: theory, state of the art, design guidelines, and future directions”, *J NeuroEngineering Rehabil*, vol. 8, n° 1, p. 22, 2011, doi: 10.1186/1743-0003-8-22.
- [74] R. T. Oğulata, “The effect of thermal insulation of clothing on human thermal comfort”, *Fibres & Textiles in Eastern Europe*, vol. 15, n° 2, Art. n° 2, 2007.
- [75] H. Farhangi, “The path of the smart grid”, *IEEE Power and Energy Magazine*, vol. 8, n° 1, Art. n° 1, ene. 2010, doi: 10.1109/MPE.2009.934876.
- [76] Y. Yoldaş, A. Önen, S. M. Muyeen, A. V. Vasilakos, y İ. Alan, “Enhancing smart grid with microgrids: Challenges and opportunities”, *Renewable and Sustainable Energy Reviews*, vol. 72, pp. 205–214, may 2017, doi: 10.1016/j.rser.2017.01.064.
- [77] M. F. Zia, E. Elbouchikhi, y M. Benbouzid, “Microgrids energy management systems: A critical review on methods, solutions, and prospects”, *Applied Energy*, vol. 222, pp. 1033–1055, jul. 2018, doi: 10.1016/j.apenergy.2018.04.103.
- [78] D. E. Olivares, A. Mehrizi-Sani, A. Etemadi, C. Cañizares, R. Iravani, M. Kazerani, A. Hajimiragha, O. Gomis-Bellmunt, M. Saadifard, R. Palma-Behnke, G. Jiménez-Estévez

- y N. Hatziargyriou, “Trends in Microgrid Control”, *IEEE Transactions on Smart Grid*, vol. 5, n° 4, Art. n° 4, jul. 2014, doi: 10.1109/TSG.2013.2295514.
- [79] A. Pina, C. Silva, y P. Ferrão, “The impact of demand side management strategies in the penetration of renewable electricity”, *Energy*, vol. 41, n° 1, Art. n° 1, may 2012, doi: 10.1016/j.energy.2011.06.013.
- [80] D. Li, W.-Y. Chiu, y H. Sun, “Chapter 7 - Demand Side Management in Microgrid Control Systems”, en *Microgrid*, M. S. Mahmoud, Ed., Butterworth-Heinemann, 2017, pp. 203–230. doi: 10.1016/B978-0-08-101753-1.00007-3.
- [81] K. S. Joshal y N. Gupta, “Microgrids with Model Predictive Control: A Critical Review”, *Energies*, vol. 16, n° 13, Art. n° 13, ene. 2023, doi: 10.3390/en16134851.
- [82] D. Ipsakis, S. Voutetakis, P. Seferlis, F. Stergiopoulos, S. Papadopoulou, y C. Elmasides, “The effect of the hysteresis band on power management strategies in a stand-alone power system”, *Energy*, vol. 33, n° 10, Art. n° 10, oct. 2008, doi: 10.1016/j.energy.2008.07.012.
- [83] C. Ziogou, D. Ipsakis, C. Elmasides, F. Stergiopoulos, S. Papadopoulou y P. Seferlis, “Automation infrastructure and operation control strategy in a stand-alone power system based on renewable energy sources”, *Journal of Power Sources*, vol. 196, n° 22, pp. 9488–9499, nov. 2011, doi: 10.1016/j.jpowsour.2011.07.029.
- [84] E. Kuznetsova, Y.-F. Li, C. Ruiz, E. Zio, G. Ault, y K. Bell, “Reinforcement learning for microgrid energy management”, *Energy*, vol. 59, pp. 133–146, sep. 2013, doi: 10.1016/j.energy.2013.05.060.
- [85] Y. Ji, J. Wang, J. Xu, X. Fang, y H. Zhang, “Real-Time Energy Management of a Microgrid Using Deep Reinforcement Learning”, *Energies*, vol. 12, p. 2291, jun. 2019, doi: 10.3390/en12122291.
- [86] J. R. Vázquez-Canteli y Z. Nagy, “Reinforcement learning for demand response: A review of algorithms and modeling techniques”, *Applied Energy*, vol. 235, pp. 1072–1089, feb. 2019, doi: 10.1016/j.apenergy.2018.11.002.
- [87] J. D. Vergara-Dietrich, M. M. Morato, P. R. C. Mendes, A. A. Cani, J. E. Normey-Rico, y C. Bordons, “Advanced chance-constrained predictive control for the efficient energy management of renewable power systems”, *Journal of Process Control*, vol. 74, pp. 120–132, feb. 2019, doi: 10.1016/j.jprocont.2017.11.003.
- [88] Y. Du, W. Pei, N. Chen, X. Ge, y H. Xiao, “Real-time microgrid economic dispatch based on model predictive control strategy”, *J. Mod. Power Syst. Clean Energy*, vol. 5, n° 5, Art. n° 5, sep. 2017, doi: 10.1007/s40565-017-0265-4.
- [89] B. Zhu, H. Tazvinga, y X. Xia, “Model Predictive Control for Energy Dispatch of a Photovoltaic-Diesel-Battery Hybrid Power System”, *IFAC Proceedings Volumes*, vol. 47, n° 3, Art. n° 3, 2014, doi: 10.3182/20140824-6-ZA-1003.00943.
- [90] B. V. Solanki, A. Raghurajan, K. Bhattacharya, y C. A. Canizares, “Including Smart Loads for Optimal Demand Response in Integrated Energy Management Systems for Isolated Microgrids”, *IEEE Trans. Smart Grid*, vol. 8, n° 4, Art. n° 4, jul. 2017, doi: 10.1109/TSG.2015.2506152.
- [91] D. Romero-Quete y J. R. Garcia, “An affine arithmetic-model predictive control approach for optimal economic dispatch of combined heat and power microgrids”, *Applied Energy*, vol. 242, pp. 1436–1447, may 2019, doi: 10.1016/j.apenergy.2019.03.159.
- [92] A. S. O. Ogunjuyigbe, T. R. Ayodele, y O. E. Oladimeji, “Management of loads in residential buildings installed with PV system under intermittent solar irradiation using mixed integer linear programming”, *Energy and Buildings*, vol. 130, pp. 253–271, oct. 2016, doi: 10.1016/j.enbuild.2016.08.042.

- [93] G. Bruni, S. Cordiner, V. Mulone, V. Sinisi, y F. Spagnolo, “Energy management in a domestic microgrid by means of model predictive controllers”, *Energy*, vol. 108, pp. 119–131, ago. 2016, doi: 10.1016/j.energy.2015.08.004.
- [94] M. Toub, C. R. Reddy, M. Razmara, M. Shahbakhti, R. D. Robinett, y G. Aniba, “Model-based predictive control for optimal MicroCSP operation integrated with building HVAC systems”, *Energy Conversion and Management*, vol. 199, p. 111924, nov. 2019, doi: 10.1016/j.enconman.2019.111924.
- [95] G. Bianchini, M. Casini, D. Pepe, A. Vicino, y G. G. Zanvettor, “An integrated model predictive control approach for optimal HVAC and energy storage operation in large-scale buildings”, *Applied Energy*, vol. 240, pp. 327–340, abr. 2019, doi: 10.1016/j.apenergy.2019.01.187.
- [96] “Situación Tarifaria”, ENERSA. Accedido: 18 de marzo de 2021. [En línea]. Disponible en: <https://www.enersa.com.ar/informacion-comercial/>
- [97] D. Limon, I. Alvarado, T. Alamo, y E. Camacho, “MPC for tracking piecewise constant reference for constrained linear systems”, *Automatica*, vol. 44, pp. 2382–2387, sep. 2008, doi: 10.1016/j.automatica.2008.01.023.
- [98] A. Ferramosca, D. Limon, A. Gonzalez, y D. Odloak, “MPC for tracking zone regions”, *Journal of Process Control - JPROCESS CONTROL*, vol. 20, pp. 506–516, abr. 2010, doi: 10.1016/j.jprocont.2010.02.005.
- [99] S. Liu, Y. Mao, y J. Liu, “Model-Predictive Control With Generalized Zone Tracking”, *IEEE Transactions on Automatic Control*, vol. 64, n° 11, Art. n° 11, nov. 2019, doi: 10.1109/TAC.2019.2902041.
- [100] A. Anderson, A. D’Jorge, A. H. Gonzalez, A. Ferramosca, y M. Actis, “MPC for tracking with maximum domain of attraction”.
- [101] P. S. C. Heuberger, P. M. J. Van Den Hof, y B. Wahlberg, Eds., *Modelling and Identification with Rational Orthogonal Basis Functions*. London: Springer, 2005. doi: 10.1007/1-84628-178-4.
- [102] G. Cimini, A. Bemporad, y D. Bernardini, “ODYS QP Solver, ODYS S.R.L”, sep. 2017, [En línea]. Disponible en: (<https://odys.it/qp>),
- [103] F. Amara, K. Agbossou, A. Cardenas, Y. Dubé, y S. Kelouwani, “Comparison and Simulation of Building Thermal Models for Effective Energy Management”, *Smart Grid and Renewable Energy*, vol. 06, pp. 95–112, ene. 2015, doi: 10.4236/sgre.2015.64009.
- [104] M. A. Fayazbakhsh, F. Bagheri, y M. Bahrami, “A Resistance–Capacitance Model for Real-Time Calculation of Cooling Load in HVAC-R Systems”, *Journal of Thermal Science and Engineering Applications*, vol. 7, dic. 2015, doi: 10.1115/1.4030640.
- [105] S. C. Vegunta, M. Higginson, Y. Kenarangui, G. Li, D. Zabel, M. Tasdighi y A. Shadman, “AC Microgrid Protection System Design Challenges—A Practical Experience”, p. 23, 2021.
- [106] S. Teimourzadeh, F. Aminifar, M. Davarpanah, y J. M. Guerrero, “Macroprotections for Microgrids: Toward a New Protection Paradigm Subsequent to Distributed Energy Resource Integration”, *EEE Ind. Electron. Mag.*, vol. 10, n° 3, pp. 6–18, sep. 2016, doi: 10.1109/MIE.2016.2569620.
- [107] Asian Development Bank, “Handbook on Microgrids for Power Quality and Connectivity”:, Asian Development Bank, Manila, Philippines, ago. 2020. doi: 10.22617/TIM200182-2.
- [108] H. Al Hassan, A. Reiman, G. Reed, Z.-H. Mao, y B. Grainger, “Model-Based Fault Detection of Inverter-Based Microgrids and a Mathematical Framework to Analyze and Avoid Nuisance Tripping and Blinding Scenarios”, *Energies*, vol. 11, n° 8, p. 2152, ago. 2018, doi: 10.3390/en11082152.

- [109] J. Hare, X. Shi, S. Gupta, y A. Bazzi, “Fault diagnostics in smart micro-grids: A survey”, *Renewable and Sustainable Energy Reviews*, vol. 60, pp. 1114–1124, jul. 2016, doi: 10.1016/j.rser.2016.01.122.
- [110] S. Jadidi, H. Badihi, y Y. Zhang, “Fault Diagnosis in Microgrids with Integration of Solar Photovoltaic Systems:A Review”, *IFAC-PapersOnLine*, vol. 53, n° 2, pp. 12091–12096, 2020, doi: 10.1016/j.ifacol.2020.12.763.
- [111] T. S S Senarathna, K. T M Udayanga Hemapala, y Department of Electrical Engineering, University of Moratuwa, Moratuwa, Sri Lanka, “Review of adaptive protection methods for microgrids”, *AIMS Energy*, vol. 7, n° 5, pp. 557–578, 2019, doi: 10.3934/energy.2019.5.557.
- [112] K. A. Wheeler, S. O. Faried, y M. Elsamahy, “A microgrid protection scheme using differential and adaptive overcurrent relays”, en *2017 IEEE Electrical Power and Energy Conference (EPEC)*, Saskatoon, SK: IEEE, oct. 2017, pp. 1–6. doi: 10.1109/EPEC.2017.8286150.
- [113] S. Baloch, S. S. Samsani, y M. S. Muhammad, “Fault Protection in Microgrid Using Wavelet Multiresolution Analysis and Data Mining”, *IEEE Access*, vol. 9, pp. 86382–86391, 2021, doi: 10.1109/ACCESS.2021.3088900.
- [114] S. Jamali, S. Ranjbar, y A. Bahmanyar, “Identification of faulted line section in microgrids using data mining method based on feature discretisation”, *Int Trans Electr Energ Syst*, vol. 30, n° 6, jun. 2020, doi: 10.1002/2050-7038.12353.
- [115] N. Bayati, E. Balouji, H. Baghaee, A. Hajizadeh, M. Soltani, Z. Lin y M. Savaghebi, “Locating high-impedance faults in DC microgrid clusters using support vector machines”, *Applied Energy*, vol. 308, p. 118338, feb. 2022, doi: 10.1016/j.apenergy.2021.118338.
- [116] “Short-Circuit Currents Information on short-circuit currents of SMA PV inverters”.
- [117] “Wire Inductance Calculator”. Accedido: 23 de junio de 2021. [En línea]. Disponible en: <https://www.ampbooks.com/mobile/amplifier-calculators/wire-inductance/calculator/>
- [118] J. J. Nedumgatt, K. B. Jayakrishnan, S. Umashankar, D. Vijayakumar, y D. P. Kothari, “Perturb and observe MPPT algorithm for solar PV systems-modeling and simulation”, en *2011 Annual IEEE India Conference*, dic. 2011, pp. 1–6. doi: 10.1109/INDCON.2011.6139513.
- [119] L. Chaar, “26 - Solar Power Conversion”, en *Power Electronics Handbook (Second Edition)*, M. H. Rashid, Ed., en Engineering. , Burlington: Academic Press, 2007, pp. 661–672. doi: 10.1016/B978-012088479-7/50044-4.
- [120] S. Choi, V. Agelidis, J. Yang, D. Coutellier, y P. Marabeas, “Analysis, design and experimental results of a floating-output interleaved-input boost-derived DC-DC high-gain transformer-less converter”, *Power Electronics, IET*, vol. 4, pp. 168–180, feb. 2011, doi: 10.1049/iet-pel.2009.0339.
- [121] S. Masri y P. W. Chan, “Design and development of a DC-DC boost converter with constant output voltage”, en *2010 International Conference on Intelligent and Advanced Systems*, Kuala Lumpur, Malaysia: IEEE, jun. 2010, pp. 1–4. doi: 10.1109/ICIAS.2010.5716257.
- [122] S. Jadhav, N. Devdas, S. Nisar, y V. Bajpai, “Bidirectional DC-DC converter in Solar PV System for Battery Charging Application”, en *2018 International Conference on Smart City and Emerging Technology (ICSCET)*, ene. 2018, pp. 1–4. doi: 10.1109/ICSCET.2018.8537391.
- [123] M. H. Rashid, *Electrónica de potencia: circuitos, dispositivos y aplicaciones*. Pearson Educación, 2004.
- [124] D. M. Rao Korada y M. K. Mishra, “DC Bus Voltage Control in Hybrid AC/DC Microgrid System”, en *2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe*

- (*EEEIC / I&CPS Europe*), Madrid, Spain: IEEE, jun. 2020, pp. 1–6. doi: 10.1109/EEEIC/ICPSEurope49358.2020.9160793.
- [125] B. M. Sarif, D. V. A. Kumar, y M. V. G. Rao, “Comparison Study of PID Controller Tuning using Classical/Analytical Methods”, vol. 13, n° 8, 2018.
- [126] J. Keller y B. Kroposki, “Understanding Fault Characteristics of Inverter-Based Distributed Energy Resources”, *Technical Report*, p. 48, 2010.
- [127] S. M. Cherati, N. A. Azli, S. M. Ayob, y A. Mortezaei, “Design of a current mode PI controller for a single-phase PWM inverter”, en *2011 IEEE Applied Power Electronics Colloquium (IAPEC)*, Johor Bahru, Malaysia: IEEE, abr. 2011, pp. 180–184. doi: 10.1109/IAPEC.2011.5779864.
- [128] Honorable Congreso de la Nación Argentina, *Régimen de Fomento a la Generación Distribuida de Energía Renovable Integrada a la Red Eléctrica Pública*. 2017. Accedido: 30 de diciembre de 2023. [En línea]. Disponible en: <https://www.argentina.gob.ar/>
- [129] *Ley 27424 Régimen de Fomento a la Generación Distribuida de Energía Renovable Integrada a la Red Eléctrica Pública*. [En línea]. Disponible en: <https://servicios.infoleg.gob.ar/infolegInternet/anexos/305000-309999/305179/norma.htm>
- [130] Legislatura de la Provincia de Entre Ríos, *Utilización de Fuentes Renovables de Energía para la Generación de Energía Eléctrica Destinada al Mercado Eléctrico*. 2021.
- [131] G. Gareis, J. Stivanello, C. Maché, A. Nakasone, F. Cuestas, M. Benito, G. Parody, S. Cuestas y M. Hammerly, “Generación de Energía Solar Fotovoltaica en Grandes Superficies Cubiertas de la Ciudad de Paraná, Entre Ríos”, presentado en ASADES, 2017.
- [132] N. M. Swarnkar, L. Gidwani, y R. Sharma, “An application of HOMER Pro in optimization of hybrid energy system for electrification of technical institute”, en *2016 International Conference on Energy Efficient Technologies for Sustainability (ICEETS)*, abr. 2016, pp. 56–61. doi: 10.1109/ICEETS.2016.7582899.
- [133] J. L. Godoy, R. M. Schierloh, y J. Vega, “Economic Evaluation of Micro-Grids with Renewable Generation”, en *2018 Argentine Conference on Automatic Control (AADECA)*, nov. 2018, pp. 1–6. doi: 10.23919/AADECA.2018.8577305.
- [134] I. Fisher, *The Rate of Interest*. Martino Publishing, 2009.
- [135] Josefina Pelaez, “Análisis de Valuación de un Parque de Energía Eólica en Argentina”, Universidad de San Andrés, Tesis final de Licenciatura en Administración de Empresas, may 2016.
- [136] C. Spagnoletta, “Review: Costo Nivelado de la Energía (LCOE): Nuevo enfoque para el análisis de proyectos de energía”, Universidad Torcuato Di Tella, 2021.
- [137] “Manual de manejo de pollos de engorde”, Aviagen, 1118-AVNAA-041, 2018.
- [138] Secretaría de Energía de Argentina, “Guía del Recurso Solar”, ISBN 978-987-47110-0-7, 2019.