

Tesis Doctoral: Ingeniería Industrial

Programa de Doctorado en Sistemas de Energía Eléctrica

Aportaciones a la gestión óptima de los recursos de generación y almacenamiento en microrredes eléctricas

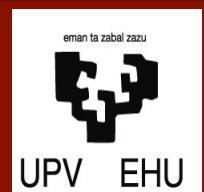


Autor: Lázaro Alvarado Barrios

Director: Dr. D. José Luis Martínez Ramos

Departamento de Ingeniería Eléctrica
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2020



Tesis Doctoral
Ingeniería Industrial
Programa de Doctorado en Sistemas de Energía Eléctrica

Aportaciones a la gestión óptima de los recursos de generación y almacenamiento en microrredes eléctricas

Autor:
Lázaro Alvarado Barrios

Director:
Dr. D. José Luis Martínez Ramos
Catedrático

Departamento de Ingeniería Eléctrica
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

2020

Tesis Doctoral: Aportaciones a la gestión óptima de los recursos de generación y almacenamiento en microrredes eléctricas

Autor: Lázaro Alvarado Barrios
Director: Dr. D. José Luis Martínez Ramos

El tribunal nombrado para juzgar la Tesis arriba indicada, compuesto por los siguientes doctores:

Presidente:

Vocales:

Secretario:

acuerdan otorgarle la calificación de:

El Secretario del Tribunal

Fecha:

A Noelvis

A mis hijos Alejandro, Daniela y Amalline

A mis padres y hermanos

A mis compañeros y profesores

Agradecimientos

Culminar este trabajo de investigación no ha sido solo el resultado de mi esfuerzo personal. En él han participado personas e instituciones a las que deseo agradecer.

Un recuerdo muy especial a Cuba.

En primer lugar agradecer a los compañeros que me han acompañado estos últimos años a convertir ideas y conocimientos en artículos científicos que sustentan y le dan valor a este trabajo: A Alvaro Rodríguez del Nozal, Daniel Gutierrez Reina, Juan Manuel Escaño y Alejandro Tapia. Un reconocimiento especial a mi tutor José Luis Martínez Ramos y a mi profesor Juan Boza Valerino por sus orientaciones y aportaciones en el desarrollo de la investigación y la producción científica obtenida. A todos muchas gracias.

A mis compañeros del Departamento de Ingeniería Eléctrica de la Universidad de Sevilla quienes me acogieron en su colectivo, y me permitieron retomar la carrera de Ingeniería Eléctrica después de 25 años. A mis compañeros del Departamento de Ingeniería de la Universidad Loyola Andalucía por permitirme ser parte de una gran familia. Debo dar las gracias por el apoyo que me han brindado para desarrollar mi carrera docente e investigadora en esta institución.

Recordar a todas las personas que durante estos años me han tendido la mano. Son muchos lo que me han ayudado económica y sentimentalmente. A todos ellos eterna gratitud.

Con especial cariño a mi compañera de viaje y novia eterna Noelvis, por su paciencia y apoyo en todo momento, por hacer del día a día una gran fiesta de amor y comprensión. Por último a mis hijos, padres y hermanos porque siempre están conmigo en la distancia.

Resumen

El sector energético está realizando una transición de una red centralizada, compuesta de plantas de energía grandes y controlables, a una red descentralizada basada en el incremento de la penetración de Recursos de Energía Distribuidos. Este cambio hacia un modelo más sostenible, plantea nuevos retos tecnológicos, asociados a la intermitencia de las fuentes de energía renovables afectadas por las condiciones climatológicas, lo que las hace difícilmente gestionables, e impactos negativos a la red eléctrica como variación de la magnitud del voltaje de suministro y el incremento de los desequilibrios en el voltaje y corrientes, entre otros.

Dentro de este contexto, las microrredes proporcionan una solución clave para integrar fuentes de energía renovables, recursos de energía controlables, cargas flexibles y sistemas de almacenamiento, en modo conectado a la red o en modo aislado. La gestión óptima de la energía es crucial para desarrollar estrategias para mejorar la eficiencia y la confiabilidad de estos pequeños sistemas de energía eléctrica.

La principal contribución científica de este trabajo de investigación es proponer una metodología para gestionar de forma óptima la energía de una microrred utilizando la Programación Horaria de las Unidades de Generación, en un entorno estocástico, al tener en cuenta los errores en la predicción de la demanda.

Esta Tesis aporta dos algoritmos, uno mediante programación lineal entera mixta (MILP) y otro con un enfoque meta-heurístico, en este caso un algoritmo genético (AG). Ambos algoritmos resuelven una función objetivo que se formula para minimizar el coste total de operación de una microrred, al tiempo que satisface restricciones técnicas, económicas y ambientales. En particular, consideran la reserva rodante de las unidades controlables capaz de cubrir el error en la estimación de la demanda en un 99,73 %, lo que garantiza la confiabilidad de la operación de la microrred en isla. Estos algoritmos son validados en una microrred formada por un generador diésel y una microturbina como unidades controladas, una turbina eólica y una planta fotovoltaica como fuentes de energía renovables no controladas y un sistema de almacenamiento de energía por baterías.

Como resultado de la investigación realizada se publicaron dos artículos en revistas indexadas en JCR y una aportación a congresos, los cuales se han utilizado para redactar la Tesis como compendio de artículos.

Abstract

The energy sector is transitioning from a centralized grid, comprised of large, controllable power plants, to a decentralized grid based on increased penetration of Distributed Energy Resources. This change towards a more sustainable model poses new technological challenges, associated with the intermittency of renewable energy sources affected by weather conditions, which makes them difficult to manage, and with negative impacts on the electrical network such as variation in magnitude supply voltage and increased imbalances in voltage and currents, among others.

Within this context, microgrids provide a key solution for integrating renewable energy sources, controllable energy resources, flexible loads, and storage systems in grid-connected or isolated mode. Optimal energy management is crucial in developing strategies to improve the efficiency and reliability of these small electrical power systems.

The main scientific contribution of this research work is to propose a methodology to optimally manage the energy of a microgrid using the Unit Commitment problem, in a stochastic environment, taking into account errors in the demand prediction.

This Thesis provides two algorithms, one using mixed integer linear programming (MILP) and the other with a meta-heuristic approach, in this case, a genetic algorithm (AG). Both algorithms solve an objective function that is formulated to minimize the total cost of operating a microgrid, while satisfying technical, economic and environmental constraints. In particular, they consider the spinning reserve of controllable units capable of covering the error in estimating demand by 99.73 %, which guarantees the reliability of the operation of the island microgrid. These algorithms are validated in a microgrid consisting of a diesel generator and a microturbine as controlled units, a wind turbine and a photovoltaic plant as uncontrolled renewable energy sources and a battery energy storage system.

As a result of the research carried out, two articles were published in journals indexed in JCR, which have been used to write the Thesis as a compendium of articles.

Índice

<i>Resumen</i>	V
<i>Abstract</i>	VII
<i>Índice de Figuras</i>	XIII
<i>Índice de Tablas</i>	XV
<i>Notación</i>	XVII
<i>Acrónimos</i>	XVII
1 Introducción	1
1.1 Motivación	1
1.2 Aportaciones	3
1.3 Estructura de la tesis	3
1.4 Publicaciones	4
2 Gestión óptima de los recursos energéticos de una microrred	5
2.1 Introducción	5
2.2 Estado del arte sobre la gestión óptima de los recursos energéticos de una microrred	6
2.2.1 PHUGyA basado en métodos clásicos	7
2.2.2 PHUGyA basado en métodos metaheurísticos	10
2.2.3 PHUGyA basado en métodos de inteligencia artificial	11
2.2.4 PHUGyA basado en programación estocástica y MPC	12
2.2.5 Problemas de objetivos múltiples	14
2.3 Contribuciones con respecto al estado del arte	16
3 Programación horaria de los recursos de generación y almacenamiento de una microrred bajo incertidumbre	17
3.1 Introducción	17
3.2 Descripción del problema	17

3.3	Modelado del sistema	19
3.3.1	Modelado de las incertidumbres y predicción de la demanda	19
3.3.2	Generador Fotovoltaico (PV)	22
3.3.3	Turbina eólica (WT)	22
3.3.4	Generador Diesel (DE)	23
3.3.5	Microturbina (MT)	23
3.3.6	Balance de Potencia	24
3.3.7	Límites de Generación	24
3.3.8	Sistema de almacenamiento de energía por baterías (BESS)	25
3.3.9	Reserva rodante	26
3.3.10	Otros Costes	28
	3.3.10.1 Coste de operación y mantenimiento de las unidades des- pachables (DE y MT).	28
	3.3.10.2 Coste de arranque de las unidades despachables (DE and MT)	28
	3.3.10.3 Coste de Emisiones	28
3.4	Estructura y datos de la microrred estudiada	29
3.4.1	Estructura de la microrred	29
3.4.2	Datos de la microrred	30
	3.4.2.1 Datos utilizados para validar el algoritmo 1	30
	3.4.2.2 Datos utilizados para validar el algoritmo 2	31
4	Algoritmos propuestos	35
4.1	Introducción	35
4.2	Enfoque de Programación Lineal Entera Mixta	35
4.2.1	Introducción	35
4.2.2	Formulación del problema	36
	4.2.2.1 Asignación de las unidades de generación y almacenamiento en un entorno estocástico	38
	4.2.2.2 Despacho Económico	39
4.2.3	Resultados de las simulaciones	40
	4.2.3.1 Caso Base	41
	4.2.3.2 Influencia de los parámetros del BESS en el problema	44
4.2.4	Conclusiones	46
4.3	Enfoque Computacional Evolutivo	47
4.3.1	Introducción	47
4.3.2	Formulación del problema.	47
	4.3.2.1 Modos de operación de la microrred	48
4.3.3	Enfoque computacional evolutivo	50
	4.3.3.1 Algoritmo Genético	50
	4.3.3.2 Estructura del algoritmo genético propuesto	50
	4.3.3.3 Implementación del algoritmo genético	53
4.3.4	Resultados de las simulaciones	54
	4.3.4.1 Configuración del algoritmo genético	54

4.3.4.2 Resultados de los casos de estudio	55
4.3.5 Conclusiones	61
5 Conclusiones	63
5.1 Contribuciones	63
5.2 Principales limitaciones	65
5.3 Futuros trabajos	65
<i>Bibliografía</i>	67
Apéndice Apendice	79
1 Artículos publicados	79
1.1 Renewable Energy (2020)	79
1.2 Energies (2019)	90
1.3 2018 International Conference on Smart Energy Systems and Technologies, (SEST 2018)	114

Índice de Figuras

2.1	Enfoques de solución a la Programación Horaria de las Unidades de Generación y Almacenamiento en microrredes	8
3.1	Diagrama de flujo del problema de la Programación Horaria de las Unidades de Generación y Almacenamiento en un entorno estocástico, extraída de [1]	19
3.2	Distribución de probabilidad del error de estimación de demanda alrededor de la media, extraída de [2]	21
3.3	Demandas de la microrred, con intervalos de confianza según el criterio 3σ , extraída de [1]	21
3.4	Estructura de la microrred considerada en el problema, extraída de [1]	30
3.5	Potencia de las unidades solar (PV) y eólica (WT) durante 24 horas, extraída de [1]	31
3.6	Coste de operación de los generadores diesel (DE) y microturbina (MT) en términos de suministro de potencia, extraída de [2]	32
3.7	Costes de arranque de las unidades despachables en términos del tiempo que ha estado apagada, extraída de [2]	32
3.8	Gráfica de demanda de potencia y de generación de las fuentes renovables, extraída de [2]	33
4.1	Cubrimiento de la curva de carga diaria. Caso base, extraída de [1]	41
4.2	Proceso de carga y descarga de la batería. Caso base, extraída de [1]	42
4.3	Estimación error (ω_t) y diferencia en las potencias entregadas ($\Delta P_{i,t}$), extraída de [1]	43
4.4	Cubrimiento de la curva de carga diaria. Caso 4, extraída de [1]	45
4.5	Proceso de carga y descarga de la batería. BESS Caso 4, extraída de [1]	45
4.6	Representación de la solución o individuos	51
4.7	Evolución del Algoritmo Genético (GA) propuesto, caso de estudio 1, cruce de dos puntos, $p_c = 0.6$ y $p_m = 0.4$, extraída de [2]	55
4.8	Solución del caso de estudio 1. Programación Horaria de las Unidades Generadoras, extraída de [2]	56

4.9	Gestión de la batería. Caso de estudio 1, extraída de [2]	57
4.10	Solución del caso de estudio 2. Programación Horaria de las Unidades Generadoras, extraída de [2]	58
4.11	Gestión de la batería. Caso de estudio 2, extraída de [2]	59
4.12	Solución caso de estudio 3. Programación Horaria de las Unidades Generadoras, extraída de [2]	61
4.13	Gestión de la batería. Caso de estudio 3, extraída de [2]	61

Índice de Tablas

2.1	Revisión bibliográfica sobre gestión óptima de energía en microrredes.	15
3.1	Datos técnicos de las unidades generadoras [3]	30
3.2	Coeficientes de costes de las unidades generadoras [3]	30
3.3	Parámetros característicos de cada una de las unidades componentes de la microrred, extraída de [2]	31
3.4	Costes de los factores externos y de emisión de la generación de la red principal, extraída de [2]	33
3.5	Parámetros característicos del Sistemas de Almacenamiento de Energía por Batería (BESS), extraída de [2]	33
4.1	Escenarios de los parámetros del Sistema de Almacenamiento de Energía por Baterías (BESS), extraída de [1]	41
4.2	Asignación de las unidades controlables. Caso base, extraída de [1]	41
4.3	Valores de la diferencia en las potencias entregadas ($\Delta P_{i,t}$) y el error (ω_t), extraída de [1]	43
4.4	Resultados por escenarios de los parámetros del Sistema de Almacenamiento de Energía por Baterías (BESS), extraída de [1]	44
4.5	Asignación de las unidades controlables. Caso 4, extraída de [1]	44
4.6	Parámetros del Algoritmo Genético (GA), extraída de [2]	54
4.7	Resultados del caso estudio 1, expresado en €, extraída de [2]	56
4.8	Resultados del caso de estudio 2, expresado en €, extraída de [2]	57
4.9	Resultados del caso estudio 3, expresado en €, extraída de [2]	59

Notación

Acrónimos

ARMA	Modelo Autorregresivo de Media Movil
BESS	Sistema de Almacenamiento de Energía por Baterías
CIGRE	Comité Internacional de Grandes Redes Eléctricas
CHP	Sistema Combinado de Calor y Energía (Cogeneración)
DE	Generador Diesel
DERs	Recursos de Energía Distribuidos
DP	Programación Dinámica
DR	Gestión activa de la demanda (Demand Response)
EESS	Sistemas de Almacenamiento de Energía Eléctrica
ED	Despacho Económico
EMS	Sistema de Gestión de Energía
FC	Celda de combustible
GA	Algoritmo Genético
LP	Programación Lineal
MGs	Microrredes
MILP	Programación Lineal Entera Mixta
MINLP	Programación No Lineal Entera Mixta
MIQP	Programación Cuadrática Entera Mixta
MT	Microturbina
MPC	Control Predictivo basado en Modelo
NLP	Programación No Lineal
PHUGyA	Programación Horaria de las Unidades de Generación y Almacenamiento
PSO	Optimización por enjambre de partículas (Particle Swarm Optimization)
PV	Generador Fotovoltaico
RESs	Sistemas de Energía Renovables
SOC	Estado de carga de la batería

Acrónimos (Continuación)

SP	Programación Estocástica
SR	Reserva rodante
UC	Asignación de las Unidades Generadoras (Unit Commitment)
SUC	Asignación de las Unidades Generadoras en un entorno estocástico (Stochastic Unit Commitment)
WT	Turbina Eólica

Parámetros

a_i, b_i and c_i	coeficientes de costes de combustible asociado a cada unidad despachable i .
P_{max_i}	Potencia máxima que puede entregar el generador i .
P_{min_i}	Potencia mínima que puede entregar el generador i .
P_{max}^c	Potencia máxima de carga del BESS en el tiempo t .
P_{max}^d	Potencia máxima de descarga del BESS en el tiempo t .
SOC_{max}	Estado de carga máximo del BESS en el tiempo t .
SOC_{min}	Estado de carga mínimo del BESS en el tiempo t .
η_c	Eficiencia de carga BESS .
η_d	Eficiencia de descarga del BESS.
$P_{t,up}^d$	Potencia real demandada por la microrred en el tiempo t .
r_i^{up}	Costo de la reserva rodante de la unidad i .
μ_t	Media de la distribución de probabilidad del error de estimación de la demanda en el tiempo t .
σ_t	Desviación típica de la distribución de probabilidad del error de estimación de la demanda en el tiempo t .
w_t	Error en el pronóstico de la demanda en el tiempo t para el caso de estudio.

Variables

$P_{i,t}$	Potencia entregada por la unidad i en el tiempo t .
SOC_t	Estado de carga del BESS en el tiempo t .
$R_{i,t}^{up}$	Reserva rodante a subir de la unidad despachable i en el tiempo t .
R_t^{up}	Reserva rodante a subir total en el tiempo t .
R_t^{down}	Reserva rodante a bajar de la unidad despachable i en el tiempo t .
R_t^{down}	Reserva rodante a bajar total en el tiempo t .
$\delta_{i,t}$ (binaria)	Estado encendido/apagado del generador i en el tiempo t .

Variables (Continuación)

 \hat{P}_t^d

Demanda estimada de la microrred en el tiempo t .

1 Introducción

1.1 Motivación

La creciente demanda de energía de la población a nivel mundial [4], junto con el aumento de las emisiones de gases de efecto invernadero y el agotamiento de los combustibles fósiles [5], ha provocado en los últimos años el inicio de una transición hacia modelos económicos más sostenibles [6], siendo necesario que esta tendencia continúe en el futuro. Como consecuencia de estas políticas, el sector eléctrico está realizando una transición de una red centralizada, compuesta de plantas de energía grandes y controlables, a una red descentralizada basada en el incremento de la penetración de los sistemas de energía renovables (*Renewable Energy Sources*, RESs) [7], [8]. Estas fuentes cubren aproximadamente el 20 % del total de generación de energía eléctrica en el mundo [9]. Este proceso introduce un nuevo paradigma en el futuro del sector, en pos de la descarbonización, la disminución de la dependencia energética exterior, y la reducción de los costes de transporte y distribución de los sistemas de energía eléctrica actuales, entre otros [10].

Una de las características más interesante del esquema distribuido radica en la facilidad de integrar gran cantidad de pequeños RESs distribuidos. En este propósito, juegan un papel importante los Sistemas de Almacenamiento de Energía Eléctrica (*Electrical Energy Storage Systems*, EESS), los cuales facilitan la integración de las energías renovables al mitigar la intermitencia de naturaleza estocástica de los recursos naturales [11]. Estos sistemas proporcionan beneficios significativos en la operación de un sistema eléctrico aislado o conectado a la red principal. Esta tecnología puede asegurar el balance entre la generación y la demanda [12], permite además aplandar la curva de demanda eléctrica, perdiendo importancia los conceptos de punta y valle, [13], reducir el coste de operación almacenando energía durante el período de bajo precio y entregando la energía acumulada durante el período de alto precio [14] y usándolo como herramienta de mejora de la calidad del servicio (evitando contingencias de la red). Además, proporciona servicios auxiliares como: respuesta inercial, reservas primarias, reserva rodante, y seguimiento de carga [15, 13]. Finalmente, prestan también servicios energéticos al usuario final en cuanto a mejora de calidad de energía entregada [16],[17].

Por tanto, el estudio de estos sistemas distribuidos se ha convertido en un área de particular interés, constituyendo un objetivo social, financiero y de inversión por parte de gobiernos y compañías de energía [18]. En este contexto de transformación de la red eléctrica existente hacia las redes inteligentes del futuro, las microrredes desempeñan un papel fundamental [19, 20, 21].

Aunque el concepto de microrred [22] se ha utilizado de manera generalizada en la literatura desde su introducción [23, 24], su definición aún es un tema de discusión. El Comité Internacional de Grandes Redes Eléctricas (*International Council on Large Electric Systems*, CIGRE) define las microrredes como: sistemas eléctricos de distribución que contienen cargas y recursos de energía distribuidos (generadores, dispositivos de almacenamiento y cargas controlables) que pueden operar en forma controlada conectadas a la red principal o aisladas [25]. El *U.S. Department of Energy Microgrid Exchange Group*, establece que la microrred es un grupo de cargas interconectadas y fuentes de energía distribuida con límites eléctricos claramente definidos que actúan como simple entidad con respecto a la red [18, 19].

En este trabajo, se asume que una microrred opera en redes de distribución de medio y bajo voltaje [26]. Está compuesta por un conjunto de cargas, unidades de generación convencionales, tales como generadores diésel (*Diesel Engine*, DE), microturbinas (*Microturbine*, MT), celdas de combustible (*Fuel Cells*, FC) o plantas combinadas de calor y energía (*Cogeneration or Combined Heat and Power*, CHP), fuentes de energía renovables, por ejemplo turbinas eólicas (*Wind Turbine*, WT) o paneles fotovoltaicos (*Photovoltaic Unit*, PV) y sistemas de almacenamiento de energía, en particular baterías (*Electrical Energy Storage Systems by Batteries*, BESS) [20]. Actúan como una entidad controlable e independiente [18], [27] y pueden operar conectadas a la red principal o desconectadas de la misma [28].

Los sistemas de gestión de energía (*Energy Management System*, EMSs) son partes importantes del control de una microrred [29]. Son capaces de operar de manera óptima generadores controlables, despachar la energía activa de las RESs y controlar el consumo de cargas siguiendo un criterio económico [30].

Los sistemas de energías distribuidos, como microrredes, permiten la generación y gestión de la energía eléctrica de forma descentralizada y cerca del lugar de consumo, utilizando Recursos de Energía Distribuidos (*Distributed Energy Resources*, DERs), fundamentalmente, RESs y EESS [7], [18]. Estos sistemas, reducen la emisión de gases de efecto invernadero, permiten minimizar las pérdidas por transporte y distribución de energía, y por tanto, aumentar la eficiencia energética de los sistemas de energía eléctrica. Actualmente, la creciente instalación de RESs, como la energía eólica (PW) y energía fotovoltaica (PV) y EESS, provocan que la gestión de las microrredes sea aún más compleja, debido a la naturaleza variable de los recursos de energía renovable. Estas características le dan un enfoque estocástico al análisis de la gestión de energía óptima de una microrred [31], y por tanto, impone importantes desafíos técnicos y de regulación en el futuro.

1.2 Aportaciones

Este trabajo de investigación como aportación principal plantea proponer una metodología para gestionar de forma óptima los recursos de generación y almacenamiento en microrredes, en un entorno estocástico.

Para ello desarrolla las siguientes contribuciones:

1. Diseñar dos algoritmos para resolver el problema de la Programación Horaria de las Unidades de Generación y Almacenamiento en una microrred, considerando los errores en la predicción de la demanda, para lograr la gestión óptima en su operación.
2. Garantizar la confiabilidad de la operación de la microrred en modo aislado, bajo la hipótesis de que la reserva rodante, tanto a subir como a bajar, debe cubrir el error en la estimación de la demanda en un 99,73 %.
3. Validar el procedimiento descrito a través de su aplicación a una microrred aislada, cuya estructura, modelo y parámetros de sus componentes sean conocidos. Presentar varios casos de estudio que permitan llegar a conclusiones razonables.

1.3 Estructura de la tesis

El trabajo está estructurado en cinco capítulos y un apéndice y se organiza de la siguiente manera:

El Capítulo 1 presenta las motivaciones que condujeron a la investigación realizada, principales contribuciones y publicaciones que respaldan esta Tesis. El Capítulo 2 expone un breve resumen con las principales aportaciones encontradas en la literatura sobre la gestión óptima de los recursos energéticos y de almacenamiento en una microrred.

El Capítulo 3 desarrolla la formulación del problema a estudiar y la metodología propuesta en esta Tesis para su solución, utilizando la Programación Horaria de las Unidades de Generación y Almacenamiento (PHUGyA), en un entorno estocástico. Muestra además, los modelos y parámetros de los componentes principales de una microrred, y propone finalmente un caso de estudio.

El Capítulo 4 presenta dos algoritmos para resolver el problema de la PHUGyA aplicado a una microrred compuesta por fuentes de energía controlables, fuentes de energía renovables, sistemas de almacenamiento de energía por baterías y demanda variable, en un horizonte de programación de 24 horas hacia delante. El primer algoritmo desarrolla un enfoque basado en Programación Lineal Entera Mixta (MILP). El segundo algoritmo utiliza un enfoque computacional evolutivo, basado en un Algoritmo Genético (GA).

El Capítulo 5 presenta las conclusiones de la Tesis, donde se informa de las principales contribuciones y limitaciones derivadas de los resultados obtenidos en la aplicación práctica mostrada en el Capítulo 4, así como propuestas de futuros trabajos.

Finalmente, en el Apéndice se incluyen las publicaciones realizadas como resultado de la investigación.

1.4 Publicaciones

- Lázaro Alvarado-Barrios, Álvaro Rodríguez del Nozal, Juan Boza Valerino, Ignacio García Vera, José L. Martínez-Ramos. "Stochastic Unit Commitment in Microgrids: Influence of the load forecasting error and the availability of energy storage". Renewable Energy. Elsevier Ltd. Vol. 146. Page. 2060-2069. 2019. Incluido parcialmente en los Capítulos 3 y 4.2.
- L. Alvarado-Barrios, A. Rodríguez del Nozal, A. Tapia, J. L. Martínez-Ramos, D. G. Reina."An Evolutionary Computational Approach for the Problem of Unit Commitment and Economic Dispatch in Microgrids under several Operation Modes". Energies. MDPI. Vol.12. Page: 21-43. 2019. Incluido parcialmente en los Capítulos 3 y 4.3.
- Alvarado Barrios, Lázaro, Boza Valerino, Juan, Rodríguez del Nozal, Alvaro, Manuel Escaño, Juan, Martínez-Ramos, José L, Gonzalez-Longatt, Francisco M. "Stochastic unit commitment in microgrids based on model predictive control". "SEST 2018, International Conference on Smart Energy Systems and Technologies".

Esta Tesis ha sido parcialmente financiada por el Ministerio de Economía y Competitividad español en virtud de las subvenciones PCIN-2015-043 y ENE2015-69597-R.

2 Gestión óptima de los recursos energéticos de una microrred

2.1 Introducción

La *International Electrotechnical Commission* en el estándar IEC 61970, define la aplicación de los EMSs en la gestión de los sistemas de energía eléctrica, como una plataforma de software que proporciona un conjunto de aplicaciones para la operación efectiva de las instalaciones de generación y transmisión de energía eléctrica, para garantizar una seguridad adecuada del suministro de energía a un coste mínimo [32]. Los EMSs para una microrred tienen características similares, abarcan tanto la gestión de la oferta de energía como la demanda mientras se satisfacen las limitaciones técnicas del sistema para lograr una operación económica, sostenible y confiable de la microrred [33]. Estos sistemas tienen como objetivo, por un lado, optimizar el funcionamiento de la microrred durante la operación interconectada, es decir maximizar su valor, lo que implica optimizar la producción de la generación local distribuida y los intercambios de energía con la red de distribución principal, y por otro lado, garantizar la confiabilidad del sistema cuando opera de manera aislada [34].

Las principales funciones de los EMSs para una microrred incluyen [29, 35]:

- Monitoreo, análisis y pronóstico de la generación de energía de los RESs y de la demanda, teniendo en cuenta los factores meteorológicos, precios de mercado de energía, entre otras informaciones.
- Realizar la programación de energía óptima de la microrred, a corto plazo, en un intervalo de tiempo generalmente de uno a tres días hacia adelante, en función de las previsiones de los RESs y la demanda de la carga, teniendo en cuenta aspectos técnicos, económicos y ambientales.
- Gestión de los flujos de potencia de los DERs en la microrred, entre esta y la red principal, y entre otras microrredes, mientras se mantienen las tensiones y frecuencia en límites aceptables.

- Facilitar una transición suave de los modos de operación de las microrredes, aislado e interconectado a red.
- Los EMSs proponen generalmente, como objetivo principal, minimizar el costo de operación de la microrred en modo aislado manteniendo su fiabilidad, y maximizar el beneficio económico en el caso de conexión a red.

En la revisión bibliográfica realizada se puede observar que se han propuesto varias estrategias o técnicas de optimización para lograr la gestión óptima de la energía en una microrred [29]. Estas formulaciones de optimización han sido aplicadas a microrredes de diferentes estructuras y composición, y se han centrado en minimizar los costes de operación de estos pequeños sistemas eléctricos de potencia, a saber, costes de mantenimiento, de combustibles, de compra de energía, etc., [29, 36]. Por tanto, se puede encontrar en la literatura que las formulaciones del problema de optimización se han clasificado en base a las funciones de coste, las restricciones, los tipos de optimización, los tipos de solución y las herramientas utilizadas para resolver el problema de optimización [29, 36, 37].

La PHUGyA es una herramienta importante para analizar la distribución de potencia óptima de la microrred [38], contribuyendo a la estabilidad y funcionamiento confiable de ella, además de poder considerar los problemas ambientales y económicos asociados a su operación [39]. Este trabajo se centra en esta técnica para dar respuesta al problema de la gestión óptima de energía de una microrred.

Desde el punto de vista metodológico la solución al problema de la PHUGyA exige dos etapas: la Asignación de las Unidades de Generación (UC) y el Despacho Económico (ED). La primera permite determinar cuáles unidades se deben sincronizar y funcionar cada hora del horizonte de planificación tomando en consideración las restricciones físicas de las unidades, el arranque y parada de las mismas, los requerimientos de la capacidad del sistema, incluyendo la reserva [40]. La decisión del despacho económico implica la distribución de la demanda del sistema y la reserva a través de las unidades generadoras en servicio durante cada hora de operación [41].

La presencia de fuentes de generación renovables distribuidas, las cuales se pueden ver afectadas por las condiciones meteorológicas, y de los sistemas de almacenamiento de energía, que permiten compensar la variabilidad asociada a la entrega de potencia de las fuentes de generación convencionales y renovables para así satisfacer la demanda en cada instante [7], [18], le dan un enfoque estocástico al análisis de la gestión de energía óptima de una microrred (*Stochastic Unit Commitment*, SUC) [31]. La relativa complejidad de este problema ha hecho que los investigadores presten atención al desarrollo de algoritmos de optimización eficientes que proporcionen resultados cercanos al óptimo y que se puedan aplicar de forma sencilla.

2.2 Estado del arte sobre la gestión óptima de los recursos energéticos de una microrred

El problema de la Programación Horaria de las Unidades Generadoras en las microrredes (UC) generalmente desde el punto de vista matemático, se plantea como un problema de optimización no lineal entero mixta (MILNP) [19, 42]. La condición de entero aparece

por la naturaleza binaria de la decisión apagado/encendido de las unidades generadoras controlables, y la no linealidad surge debido a la no linealidad de las curvas de coste de combustible asociadas a estas unidades, y de las ecuaciones de la red en su caso. Estas características incrementan la dificultad para resolver el problema de optimización que permite gestionar de forma óptima la energía en las microrredes.

La incertidumbre en el problema de la programación horaria de los recursos energéticos y de almacenamiento en microrredes, en general, está representada por la formulación de un conjunto de escenarios, que se realiza sobre la base de las predicciones de la demanda y la generación de las fuentes de energía renovables. En contraste, los enfoques deterministas se usan comúnmente donde se considera un escenario único [43, 44]. Dadas estas características, los enfoques estocásticos son cruciales para abordar la gestión óptima de las microrredes [31], SUC, lo que ha motivado varios estudios en la literatura [36, 42, 45]. Estos enfoques contribuyen a la robustez de la solución, haciéndolos más apropiados para la implementación real en microrredes.

Los autores en [36] realizaron una revisión de los objetivos de optimización, restricciones, herramientas y algoritmos utilizados en los sistemas de gestión de energía para microrredes. Proporciona una breve revisión de los principales métodos de optimización utilizados; estos son, Programación Lineal (LP), Programación Lineal Entera Mixta (MILP), Programación No Lineal (NLP), Programación Estocástica (SP), y Programación Dinámica (DP). Diversos autores han utilizado diferentes enfoques de solución para resolver el problema de optimización relacionado con la gestión de energía en microrredes [36, 29]. Las técnicas de optimización más utilizadas son: Métodos de Optimización Heurística, Modelo Basado en Agentes (*Agent-Based Model*, ABM) , Enfoque Evolutivo, dentro de estos, Optimización de Enjambre de Partículas (*Particle Swarm Optimization*, PSO), Algoritmos de Colonia de Hormigas (*Ant Colony Optimization*, ACO) y Algoritmos Genéticos (*Genetic Algorithm*, GA). Otros enfoques como los Modelos basados en Control Predictivo (*Model Predictive Control*, MPC) y Redes Neuronales (*Neural Network*, NN) son ampliamente utilizados en la literatura.

Un gran número de algoritmos han sido propuestos en los últimos años para la solución de la PHUGyA aplicada a microrredes con diferentes arquitecturas, integradas por fuentes de energías controlables o no y sistemas de almacenamiento de energía, operando de forma aislada o conectadas a la red. La Figura 2.1 muestra una clasificación, elaborada en el contexto de esta Tesis, de los métodos mas utilizados para resolver el problema de la Programación Horaria de las Unidades Generadoras (UC), a partir de la literatura revisada [36, 29, 46].

2.2.1 PHUGyA basado en métodos clásicos

Son muchos los trabajos que se encuentran en la literatura que presentan la formulación del problema del UC como programación no lineal entera mixta (MINLP). No obstante, a la alta eficiencia de este enfoque, debido a que representa un modelo de optimización más real de la microrred, y por tanto, la solución del problema de optimización es más exacta, se debe resaltar que el coste computacional es mayor, provocado por las relaciones no lineales de las variables presentes en la formulación matemática. Para contrarrestar este inconveniente se han sugerido diversas propuestas; la mayoría plantean linealizar los

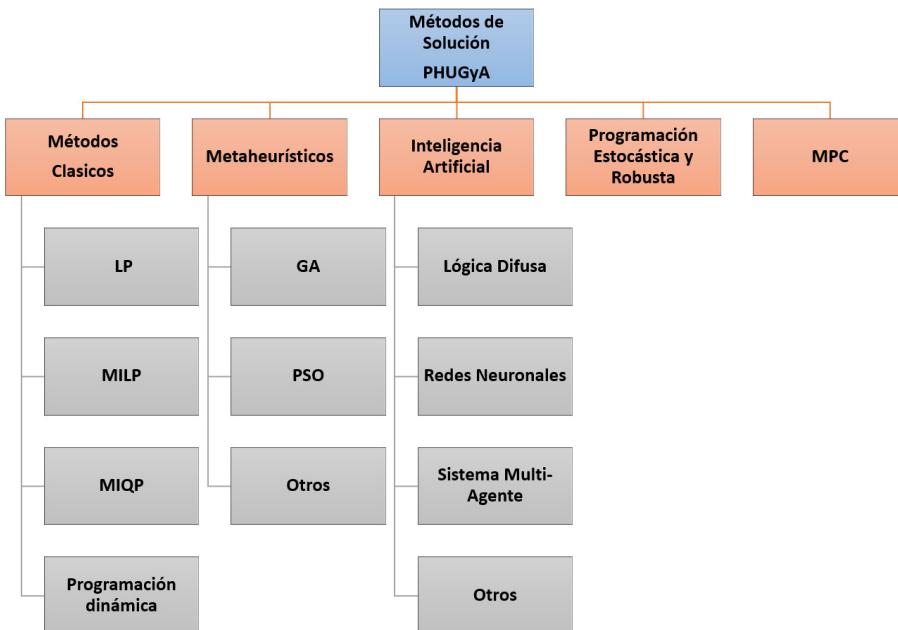


Figura 2.1 Enfoques de solución a la Programación Horaria de las Unidades de Generación y Almacenamiento en microrredes.

términos cuadráticos presentes en la función objetivo a optimizar. Ejemplos de ellos son: [47, 48, 49, 50, 51, 52]

En [47] los autores proponen resolver el problema del UC para programar un conjunto de unidades generadoras en el horizonte de planificación de 24 horas, con el objetivo de maximizar el beneficio por la entrega de energía, teniendo en cuenta una penalización por emisiones de CO_2 . El problema se presenta como MINLP, pero la función de coste de combustible cuadrática y la función de emisiones, se aproximan por funciones lineales por partes (*piecewise linear approximation*), transformando el problema a MILP.

Una estrategia similar se emplea en [48] donde se propone resolver una función objetivo para minimizar los costes asociados a la generación de energía, sistemas de almacenamiento de energía y la compra de energía a la red principal, en una microrred que opera en modo conectado. Se formula como un problema de MILNP. Para reducir la carga computacional las ecuaciones del flujo de potencia y las restricciones no lineales se simplifican mediante métodos de linealización por partes, convirtiendo el problema en MILP. El UC propuesto se prueba en una microrred de 14 barras, operando tanto en modo aislado como conectado a la red.

Los autores en [49] proponen minimizar el coste total de energía pronosticado para un día de las viviendas inteligentes de un edificio, que conforma una microrred, mientras se distribuye el coste de manera justa entre todos los integrantes. La microrred puede operar de forma autónoma y conectada a la red. Las casas comparten DERs, almacenamiento térmico, eléctrico, y generador CHP (*Combined Heat and Power*). La función objetivo se

formula como un modelo de MILP y utiliza para su solución técnicas de programación por metas minimax lexicográficas (*Lexicográfico minimax*) [53]. Este enfoque consiste inicialmente en crear niveles de prioridades para cada objetivo a optimizar, posteriormente esta técnica encuentra aquellas soluciones que verifiquen los niveles de prioridad impuestos a la función objetivo y proporciona la solución. Este método se implementó utilizando CPLEX en GAMS (*General Algebraic Modeling System*).

En [50] consideran una microrred operando de forma no conectada y conectada a la red. En modo aislado, proponen una función objetivo para minimizar el coste total de operación. En modo interconectado, el objetivo es maximizar el beneficio, para ello determina el requisito óptimo de la reserva rodante de las unidades generadoras controlables y el almacenamiento. Para la solución del problema de optimización propone un método de programación estocástica, en un horizonte de programación diaria. La optimización se resuelve mediante MILP. En este trabajo se linealizan las restricciones asociadas a la probabilidad de pérdida de cargas y energía esperada no suministrada mediante un método de optimización binivel.

Los autores en [51] proponen una formulación matemática para minimizar el coste total de operación de una microrred, integrada por una turbina eólica (WT), un panel fotovoltaico (PV), una celda de combustible, una microturbina (MT), un generador diésel (DE) y una batería (BESS). Consideran en el problema de optimización restricciones asociadas a la capacidad de la microrred para operar en modo isla, por tanto, incorpora la reserva rodante que aportan las unidades generadoras controlables. El UC se modela como MILP. Para su solución utiliza una aproximación de intervalos múltiples (*multi-interval approximation*) [54], teniendo en cuenta las distribución de probabilidades de los errores en el pronóstico del viento y la demanda. Las simulaciones numéricas se codifican en Matlab y se resuelve con el solucionador MILP de CPLEX.

En [52] aplican un UC a un sistema de energía híbrido que contiene unidades térmicas, hidráulicas y eólicas. Propone una función objetivo para minimizar el coste total de operación de la microrred. Plantea un modelo basado en MILP. Para su solución utiliza el método matemático de simetría estática en la programación lineal entera mixta (*static symmetry in mixed integer linear programming*) sugerido en [55]. Los autores imponen restricciones jerárquicas en diferentes partes del sistema de potencia, con el objetivo de disminuir la simetría en el modelo del UC, dado por las variables de estado de las unidades generadoras idénticas en el sistema. Los resultados muestran que en la medida que aumenta el dimensionamiento del sistema de energía, el rendimiento del algoritmo no es adecuado, debido al incremento de los problemas de simetría.

La programación cuadrática entera mixta (MIQP) también se usa para hacer frente al problema de la PHUGyA. Dos trabajos que utilizan esta técnica se pueden encontrar en [56, 57]. En [56] los autores formulan el problema del despacho de una microrred que busca maximizar el beneficio por la entrega de energía, al mismo tiempo que satisface las restricciones técnicas, ambientales y las fluctuaciones de la demanda, teniendo en cuenta el criterio de gestión activa de la demanda (*Demand Response*, DR), en este caso basado en precios. En [57] el objetivo es determinar la capacidad óptima de la batería de la microrred experimental de la Universidad Griffith, compuesta por fuentes de energía renovables (PV y WT) y convencionales (MT y DE) y sistemas de almacenamiento (BESS), con el objetivo de reducir los costes de operación.

Los algoritmos de programación dinámica (DP) permiten crear subproblemas del problema de optimización. Obtiene la solución óptima de cada subproblema por separado, y la combinación de estas soluciones encontradas permite expresar la solución óptima del problema de optimización planteado inicialmente [58]. En los trabajos [59, 60] plantean una función objetivo para optimizar los recursos energéticos y el comercio de energía de una microrred con la red principal. Para ello, subdivide el problema en un subproblema por cada tramo del horizonte de programación horaria de la microrred. No es habitual esta técnica de optimización cuando se quiere incorporar al problema la reducción del efecto de la contaminación de las unidades convencionales y criterios asociados a la gestión activa de la demanda (DR) [29]

2.2.2 PHUGyA basado en métodos metaheurísticos

Además de los enfoques MILP, MINLP y MIQP, hay una amplia gama de algoritmos que se pueden encontrar en la literatura para abordar el problema de la programación horaria en microrredes [61, 62]. El uso de algoritmos evolutivos para abordar este problema parece una estrategia efectiva. En la mayoría de los trabajos el problema del UC aplicado a microrredes conectadas y/o aisladas generalmente se modela utilizando un problema de optimización de un solo objetivo con múltiples restricciones, donde el objetivo principal es minimizar el coste total de operación [61, 63, 64, 65].

Un método de optimización híbrido para la solución del problema de la gestión de energía en una microrred basado en un enfoque metaheurístico se propone en [61]. Primero, el problema de optimización para minimizar el coste de operación de una microrred, que considera la función de coste de combustible cuadrática de los generadores distribuidos controlables, y los estados de arranque y apagado de estos, se modela como MILNP. Luego, el problema de optimización se descompone en dos subproblemas. El problema de la Asignación de Unidades (UC), que determina los estados de activación y desactivación de cada unidad generadora controlable, se trata como un problema de programación entera (IP). Una vez que se decide que generadores entregan potencia, se aplica el Despacho Económico (ED), para ello se utiliza un modelo de programación no lineal (NLP). Después de eso, el algoritmo genético (*Genetic Algorithm*, GA) y el algoritmo de punto interior (*interior-point algorithm*) se emplean para resolver el problema de IP y PNL respectivamente.

Un Algoritmo Genético (GA) se propone en [63] para resolver simultáneamente los problemas de la Asignación de Unidades (UC) y del Despacho Económico (ED) en una microrred conectada en baja tensión, que tiene 21 barras, integrada por 1 planta WT, 6 unidades PV, 1 unidad MT, 2 grupos electrógenos diésel (DE), 1 pila de combustible (FC), 1 BESS y 13 cargas. Dos funciones objetivo son formuladas por los autores. En la primera el optimizador EMS, minimiza el coste total de operación de la microrred, que incluye el coste de consumo de combustible, el coste de operación y mantenimiento, y el coste de arranque y parada de las unidades de generación controlables (2 DE y 1 MT). También incorpora el coste de envejecimiento del BEES y el coste de energía intercambiada con la red principal. En la segunda función objetivo propone minimizar el coste de emisiones de gases de efecto invernadero en la operación de la microrred. El comportamiento y la efectividad del GA se verifica con su aplicación a un conjunto de casos de estudio. Los resultados de la simulación demuestran un buen comportamiento del optimizador,

en términos de tiempo de computación y robustez en el modo de operación conectado a la red, en contraste con el modo de operación aislado donde se incrementa el tiempo de computación.

Los autores en [64] proponen una función objetivo utilizando un modelo MILNP, el cual se basa en la función de coste de combustible cuadrática de las unidades de generación controlables. El objetivo es minimizar el coste de producción de energía, y por tanto, lograr una distribución óptima de la generación de energía de los DERs de una microrred, integrada por 2 plantas PV, 3 plantas WT y 1 sistema combinado de energía y calor (CHP). En este artículo, se desarrolla un optimizador utilizando un enfoque metaheurístico, al que denomina Algoritmo Genético basado en Memoria (*Memory-Based Genetic Algorithm*, MGA) [66]. En comparación con el GA, el MGA utiliza sistemas de memoria para reutilizar la información útil almacenada con el objetivo de mejorar su rendimiento. Los resultados se comparan con dos variantes del método Optimización del Enjambre de partículas (PSO), obteniendo un resultado significativamente superior.

Similarmente los autores en [65] proponen aplicar el problema del UC a una microrred, integrada por 1 unidad WT, 1 unidad PV, 1 BESS, y 4 fuentes de energía controlables. Proponen dos funciones objetivo, en dependencia de los modos de operación de la microrred. En modo isla, el objetivo es minimizar el coste total de la energía a producir, y en modo interconectado, el objetivo es maximizar el beneficio. La optimización está sujeta a restricciones técnicas de la red y de reserva rodante de las unidades de generación controlables. Los autores proponen para resolver el problema del UC un algoritmo genético mejorado con la integración de la técnica de recocido simulado (*Simulated Annealing Technique*, SA). Esta técnica permite acelerar la búsqueda de soluciones, y encontrar una buena aproximación al valor óptimo de la función, y evitar que la búsqueda pueda quedar atrapada por puntos óptimos locales. A este valor óptimo se lo denomina "óptimo global" [67].

2.2.3 PHUGyA basado en métodos de inteligencia artificial

En [68] se propone un modelo difuso de objetivos múltiples (*Fuzzy Multi-Objective Model*), para lograr la gestión óptima de energía de una microrred, integrada por unidades de generación controlables (DE, MT, FC) y de energía renovables (WT y PV). El primer objetivo es minimizar el coste de operación de la microrred, que incluye el coste de combustible, coste de arranque y parada y coste de operación y mantenimiento. El segundo objetivo plantea minimizar el coste de las emisiones de efecto invernadero provocado por las unidades de generación convencionales (MT y DE). Ambos problemas están sujetos a restricciones técnicas y de minimización de pérdidas de la red. En este artículo los autores utilizan para la solución del problema un algoritmo basado en la Optimización Binaria por Enjambre de Partículas (*Binary Particle Swarm Optimization*, BPSO), al cual, se le mejora su capacidad de búsqueda a través de un enfoque caótico (*Chaotic Binary Particle Swarm Optimization*, CBPSO). Esta técnica permite que el enjambre se mueva hacia nuevas regiones de búsqueda para lograr mayor diversidad en el enjambre y evitar que se concentre en una región reducida del espacio de solución, es decir evita que la información se propague con rapidez entre las partículas y se agrupen alrededor del primer óptimo local que encuentren.

Otros trabajos basados en lógica difusa (*fuzzy logic*) se proponen en [69, 70, 71]. El primero expone un EMS basado en un control de lógica difusa de baja complejidad (*Fuzzy Logic Control*, FLC), con el objetivo de minimizar las fluctuaciones y los picos de potencia en el intercambio de energía de una microrred compuesta por RESs y BESS con la red principal. La estrategia de gestión de energía propuesta utiliza pronósticos de generación y demanda para anticipar el comportamiento futuro de la microrred. En el segundo, los autores aplican un SUC en el sistema de 39 barras de IEEE, con el objetivo de minimizar el impacto de las incertidumbres asociada a la penetración de energía eólica y la variabilidad de la demanda en los costes de operación del sistema. En el tercero, se proponen dos objetivos, uno para garantizar la disponibilidad de energía continua a las cargas, sin interrupciones, cuando una microrred integrada por RESs y BESS, opera de forma aislada y el segundo maximizar el beneficio en el intercambio de energía con la red principal y con otras microrredes. En particular, este estudio se centra en la aplicación de un Algoritmo Genético Jerárquico (*Hierarchical Genetic Algorithm*, HGA) para ajustar los parámetros del FLC.

En [72, 73] utilizan las redes neuronales (*Neural Network*, NN) para resolver distintos tareas de un EMS para una microrred. En el primero, utilizan el método de intervalos de predicción (*prediction intervals*, PIs) basado en redes neuronales no paramétricas, para determinar la incertidumbre en el pronóstico de la energía eólica de una microrred. Para cada hora, se ajustan los límites superior e inferior de la predicción de energía eólica utilizando una función de distribución acumulativa empírica (*Empirical Cumulative Distribution Function*, ECDF). El método de simulación de Monte Carlos se utiliza para generar los escenarios a partir del ECDF. Luego, los escenarios de energía eólica se incorporan en un modelo estocástico de unit commitment (SUC). Posteriormente usan un GA para resolver el problema de la PHUGyA con el objetivo de minimizar el coste de generación de una microrred, que incluye el coste de combustible y el coste de la reserva. El segundo, propone un algoritmo basado en un enfoque de red neuronal de programación de Lagrange (*Lagrange Programming Neural Network*, LPNN) [74, 75], para resolver una función de objetivo único, que propone minimizar de manera combinada el coste de generación de energía y el coste de emisiones de gases de efecto invernadero, en una microrred híbrida, integrada por RESs (WT y PV), fuentes de generación controlables (DE, MT, FC) y BEES.

2.2.4 PHUGyA basado en programación estocástica y MPC

En [62], se propone un procedimiento para integrar las incertidumbres en el pronóstico de la demanda y el viento en el problema del UC utilizando el método de árbol de escenarios múltiples. Los errores en la predicción de la demanda y el viento se modelan usando el error porcentual absoluto medio (*Mean Absolute Percentage Error*, MAPE) [76], y usa simulación por Monte Carlos para generar los escenarios que consideran dichas incertidumbres para cada hora del día. La función objetivo minimiza los costes totales de operación e incluye la determinación de la reserva rodante que se requiere para proteger un sistema de energía de aumentos repentinos de carga y variabilidad de la velocidad del viento, e incorpora su coste al problema matemático. Para optimizar el problema del unit commitment estocástico (SUC) los autores aplican el método de lista de

prioridades (*Priority List Method*) [77]. Se utilizó el sistema de prueba de 118 barras del IEEE modificado y se compararon los resultados con diferentes requisitos de reserva y costes operativos para cada caso.

Otros enfoques estocásticos se pueden encontrar en [78, 79]. En el primero [78] proponen un EMS para una microrred agrícola conectada a una red de media tensión. La microrred posee un sistema de riego que tiene dos depósitos de agua ubicados en diferentes niveles, los cuales, actúan como planta generadora de almacenamiento por bombeo, además se beneficia de un generador eólico (WT). El EMS propone una función objetivo que se formula como un problema MINLP para minimizar el coste de operación de la microrred, considera el costo de compra de energía en el mercado de producción de energía eléctrica y los costes en la operación de la unidad de almacenamiento por bombeo. Incluye en el optimizador los errores en la predicción del viento y de los precios de la energía, utilizando el modelo de estimación de puntos (*Two-Point Estimate Method, TPEM*) [80]. El problema se resuelve con el software GAMS usando el solucionador SBB para modelos MINLP.

El segundo [79], propone un EMS para una microrred que opera de forma aislada, y cuenta con RESs (PV y WT) que funcionan en todo momento en su punto de máxima potencia y EESs (baterías y tecnología de almacenamiento de hidrógeno). La función objetivo propone minimizar el coste de operación de la microrred, considerando los costes de utilización de los sistemas de almacenamiento de hidrógeno y baterías. Incorpora en el problema los errores en la predicción de la demanda, velocidad del viento e irradiancia solar, usando una función de distribución de probabilidad (*Probability Distribution Function, PDF*). La generación de escenarios se lleva a cabo mediante una discretización de la curva PDF, según [81, 82]. El problema de optimización se formula como MINLP, pero utiliza una aproximación lineal por partes (*Piecewise Linear Approximation*) [83], para resolver el problema como MILP, utilizando el solucionador de optimización Gurobi (*Gurobi Optimizer*).

Recientemente son muchos los trabajos que se publican en la literatura especializada sobre el diseño de Sistemas de Gestión de Energía (EMSs) utilizando el Control Predictivo Basado en Modelo (*Model Predictive Control, MPC*) para microrredes que incluyen fuentes de energía renovables (REEs) y sistemas de almacenamiento de energía de diferentes tecnologías (EESS) [34]. El MPC es una estrategia de control óptimo basado en el uso de un modelo dinámico de la microrred para predecir el comportamiento futuro de esta [84]. Para ello, el MPC propone resolver un problema de optimización en un horizonte de predicción, generalmente 24 horas, que frecuentemente, consiste en minimizar todos los factores que introducen costes en la microrred. Como resultado de la optimización, se obtiene una secuencia para cada una de las variables de control futuras. El controlador MPC aplica sólo el instante inicial, calculado para cada variable de control. Una vez aplicado y captado el estado del sistema, el MPC vuelve a recalcular la secuencia para el mismo horizonte de predicción, habiendo dado un paso hacia delante (para más información ver [85]). El MPC va desplazando el horizonte hacia delante, en cada tiempo de cálculo. Se dice que el MPC es una estrategia con horizonte deslizante o rodante (*receding horizon or rolling horizon*). Esto hace que en cada paso de la secuencia de control, el controlador tiene una realimentación del estado, lo que le diferencia de otras estrategias de control óptimo.

Ejemplos de EMSs diseñados para microrredes utilizando enfoques de MPC se muestran

en los siguientes trabajos: En [86] el EMS propuesto incluye una función objetivo para minimizar el coste de operación de una microrred compuesta por 2 PV, 2 WT, 1 DE y 1 BEES. Se formula como un problema de MILNP, pero utilizando la aproximación lineal por partes convierte el problema de optimización en un problema de MILP. El EMS se resuelve utilizando (UC) con una estrategia de horizonte móvil (*Rolling Horizon, RH*). Utiliza un horizonte de predicción para las variables de entrada y las condiciones iniciales de las variables de 48 horas y un tiempo de muestreo de 15 minutos. El problema de optimización MILP se resuelve utilizando el software comercial CPLEX versión 2.1. Similar enfoque se aplica en los artículos [87, 88] para la optimización en tiempo real basada en MPC de un sistema integrado por múltiples microrredes interconectadas, donde cada una propone funciones objetivos para optimizar sus propios recursos energéticos. En el primero, propone un algoritmo con un enfoque metaheurístico (*dimensionally-distributed PSO*) [89] y en el segundo, se presenta una formulación matemática de MILP que se implementa en GAMS y es resuelto usando CPLEX.

2.2.5 Problemas de objetivos múltiples

En los últimos años, algunos autores han propuestos diseños de EMSs para microrredes utilizando la herramienta UC cuya formulación requiere la optimización simultánea de más de un objetivo, generalmente en conflictos llamada optimización de objetivos múltiples (*Multiobjective Optimization*) [90]. Consiste, por tanto, que el EMS para microrredes no va a encontrar una solución óptima única, sino un conjunto de soluciones óptimas que reflejen la compensación entre todos los objetivos de decisión considerados en el problema de optimización [91]. Existen varios métodos para resolver el conflicto entre objetivos, el más utilizado en la literatura de investigación de operaciones es la solución no dominada u óptimo de Pareto (*Pareto Front*) [92]. Otros como el método de suma ponderada (*Weighted Sum Model, WSM*), método de la programación por metas (*Goal Programming, GP*) y métodos basados en la asignación de prioridades (*Prioritization-Based Methods*), también son validos [93]. Estos métodos en combinación con algoritmos evolutivos, son utilizados por distintos autores para resolver problemas de optimización multiobjetivo en microrredes (*Multi-Objective Evolutionary Algorithms*) [94].

En [39] proponen el diseño de un EMS para una microrred conectada en baja tensión que contiene 22 barras, 12 DERs (6 PV, 1 WT, 2 MT, 1 FC y 2 DE). Ambos algoritmos proponen minimizar el coste total de la operación de la microrred que incluye las transacciones diarias del mercado, los costes de combustible y los costes de mantenimiento de las unidades controlables y las pérdidas de la red, al mismo tiempo que intenta minimizar la emisión de gases de efecto invernadero y la dependencia de la microrred de la red principal y el mercado de electricidad, sujeto al cumplimiento de las restricciones de topología de la red. Los autores para diseñar el EMS definen cinco modos de operación de la microrred, donde cada uno plantea una función objetivo a optimizar con sus respectivas restricciones. Desarrollan dos algoritmos de optimización basados en Algoritmos Genéticos (AG) y MILP combinado con el método de lista de prioridades (*priority list method*), que permite establecer prioridades entre los distintos objetivos, teniéndose en cuenta su importancia relativa durante el proceso de optimización.

Similar procedimiento de optimización multiobjetivo utilizan los autores en [95] para

minimizar el costo de generación de energía y maximizar la vida útil de las baterías de plomo-ácido. Los autores han utilizado un algoritmo genético de clasificación no dominado (*Pareto Front*) para resolver el problema [96]. En [97, 98] se propuso un enfoque multiobjetivo para el diseño de EMSs de sistemas de múltiples microrredes. En el primero, se propone un algoritmo de sistema inmune artificial (*Artificial Immune System, AIS*) [99], utilizando la búsqueda de soluciones óptimas de Pareto. En el segundo, se propone un algoritmo basado en optimización adaptativa cognitiva parametrizada (*Parameterized Cognitive Adaptive Optimization, PCAO*) [100].

La Tabla 2.1 muestra un resumen de los artículos consultados para elaborar el estado del arte sobre la gestión de los recursos energéticos de una microrred.

Tabla 2.1 Revisión bibliográfica sobre gestión óptima de energía en microrredes^a.

Ref. no.	Función Objetivo	Tipo	Microrred	Enfoque	Estrategia
[47]	max ER	SO	GC	DUC	MILP
[48]	min f(OC, EESS, EP, NL)	SO	SA, GC	DUC	MILP
[49]	min OC	SO	GC	DUC	MILP
[50]	min OC, max ER	SO	SA, GC	SUC	MILP
[51]	nin f(OC, EC)	SO	CG	DUC	MILP
[52]	min OC	SO	GC	DUC	MILP
[56]	max ER (DR)	SO	GC	SUC	MIQP
[57]	min OC	SO	GC	DUC	MIQP
[59, 60]	min OC	SO	SA/GC	DUC	DP
[61]	min OC	SO	GC	DUC	GA + IP (UC), NLP(ED)
[63]	min OC	SO	SA	DUC	EGA
[64]	min OC	SO	SA	DUC	MGA
[65]	min OC, max ER	SO	SA and GC	DUC	GA + SA
[68]	min EC, min NL	SO	SA	SUC	fuzzy logic (BPSO, CBPSO)
[69]	min OC	SO	GC	SUC	fuzzy logic
[70]	min OC	SO	SA	SUC	fuzzy logic
[71]	max G	SO	SA	SUC	fuzzy logic + GA
[72]	min GC	SO	GC	DUC, SUC	NN + GA
[73]	min GC	SO	GC	DUC, SUC	NN + GA
[62]	min GC, min SUC + SDC	SO	GC	SUC	SP
[78]	min f(OC, EESS)	SO	GC	SUC	SP
[79]	min f(OC, EESS)	SO	SA	SUC	SP
[86]	min OC	SO	SA	SUC	MPC (MILP)
[87]	min OC	SO	GC	SUC	MPC (MILP)
[88]	min OC	SO	GC	SUC	MPC (MILP)
[39]	min (OC, EC), max (SA (MG))	MO	SA, GC	DUC	GA, MILP
[95]	min f(OC), nax f(BEES)	MO	SA, CG	DUC	GA
[97]	min(CO), max (ER)	MO	SA, CG	SUC	AIS, PF
[98]	min(CO), max (PV)	MO	SA, CG	SUC	PCAO

^a Nomenclatura:

Función Objetivo: Costes de Operación (CO), costes de Emisiones (EC), Costes de Compensación por deslóstro de cargas (CCLS), Pérdidas de Red (NL), Ganancia (ER). **Tipo:** Simple Objetivo (SO), Multiobjetivo (MO). **Microrred:** Aislada (SA), Conectada a la Red (GC). **Enfoque:** Unit Commitment Determinista (DUC), Unit Commitment Estocástico (SUC). **Estrategia:** Programación Entera (IP), Programación No Lineal (NLP), *Simulated Annealing* (SA), Programación Lineal de Enotros Mixtos (MILP), Programación Dinámica (DP) Algoritmo Genético (GA), Algoritmo Genético Mejorado (EGA), *Binary Particle Swarm Optimization (BPSO)*, *Chaotic Binary Particle Swarm Optimization (CBPSO)*, fuzzy logic, Redes Neuronales (NN), Programación Estocástica (SP), Control Predictivo (MPC)

2.3 Contribuciones con respecto al estado del arte

Las principales contribuciones científicas de este trabajo de investigación al estado del arte son:

1. Propone una metodología para el diseño de un Sistema de Gestión de Energía (EMS) para una microrred. Utiliza la Programación Horaria de las Unidades de Generación y Almacenamiento, en un entorno estocástico, para realizar la programación óptima de los recursos energéticos de la microrred, (Capítulo 3).
2. Desarrolla una estrategia de optimización, en la que como contribución incorpora en el algoritmo del EMS una variable de control basada en la regla empírica tres veces la desviación estándar $3\sigma_t$. Esta condición garantiza la operación confiable de la microrred en modo aislado en un 99,73 % (Capítulos 3 y 4).
3. Aporta dos algoritmos, desarrollados en el Capítulo 4, para resolver el problema de la Programación Horaria de las Unidades de Generación y Almacenamiento. Utilizan para su solución, el primero, un enfoque de MILP y el segundo, un enfoque computacional evolutivo basado en algoritmo genético (GA).

Ambos algoritmos:

- Modelan el problema de optimización como un problema de MINLP.
- Incluyen en el modelado de la carga de la microrred, la predicción de la curva de demanda y estiman el error en dicho pronóstico, cada hora, en un horizonte de programación 24 horas en adelante.
- Incorporan en el problema de optimización restricciones de confiabilidad que garantizan la operación de la microrred en modo isla. Este criterio contribuye a la robustez de la solución del problema.
- Consideran la contribución de la reserva rodante para mantener el equilibrio de la generación y la variabilidad de la demanda en la operación en tiempo real de la microrred en cualquier instante de tiempo.
- Estos algoritmos son validados en una microrred formada por unidades de generación controlables (MT y DE), fuentes de energía renovables (PV y WT), un sistema de almacenamiento de energía por baterías (BESS) y demanda variable.

3 Programación horaria de los recursos de generación y almacenamiento de una microrred bajo incertidumbre

3.1 Introducción

Este capítulo presenta la formulación del problema de la Programación Horaria de los Recursos Energéticos y de Almacenamiento de una microrred en un entorno estocástico. Posteriormente, muestra los modelos de cada componente de una microrred y los costes asociados a ellos. Finalmente, propone la estructura de la microrred y los parámetros de cada elemento que la componen, utilizados para validar los dos algoritmos propuestos en el Capítulo 4.

3.2 Descripción del problema

Las microrredes pueden funcionar conectadas a la red principal o en modo independiente. En el modo conectado a la red, la red principal realiza generalmente la regulación de voltaje y frecuencia. Dado que la red principal en los países occidentales tiene una disponibilidad muy alta, la tarea principal de la microrred no será garantizar el suministro de energía a los usuarios finales, sino injectar energía a la red principal cuando los precios son altos y comprar energía de la red cuando los precios son bajos. Además, las microrredes conectadas a la red proporcionan una mejor manera de interconectar los RESs con la red principal, maximizando potencialmente su rendimiento energético [101].

Por otro lado, si la microrred funciona en modo autónomo, es necesario controlar las fuentes de energía distribuidas para garantizar la estabilidad de voltaje y frecuencia de la microrred. Además, el equilibrio energético debe respetarse estrictamente en cualquier

momento. El concepto de microrred es vital para gestionar la creciente demanda de energía a través de la producción local de energía, así como para reducir las emisiones de gases de efecto invernadero promoviendo los RESs [20, 101].

Para el diseño de EMSs para microrredes, se pueden utilizar diferentes herramientas, como son el Flujo de Carga Óptimo (*Optimal Power Flow*), Despacho Económico (*Economic Dispatch*, ED), Programación Horaria de las Unidades de Generación (*Unit Commitment*, UC), entre otras [38]. Dadas la presencia de fuentes de energía renovables intermitentes y la variabilidad de la demanda, los enfoques estocásticos son cruciales para abordar la gestión óptima de las microredes [31]. Este problema ha sido tratado en diferentes estudios en la literatura consultada, por ejemplo, [36, 42, 45], contribuyendo a la robustez de la solución.

En este trabajo se propone el diseño de un EMS para una microrred utilizando la herramienta de la Programación Horaria de las Unidades de Generación, (*Unit Commitment*, UC), considerando la incertidumbre en la predicción de la demanda. A diferencia de la mayoría de los trabajos consultados (ver Capítulo 2), que proponen EMSs para microrredes que operan de forma conectada a la red, en este trabajo se propone un EMS para el caso más desfavorable de operación de la microrred, el funcionamiento confiable en isla.

El EMS propone un problema de optimización cuyo objetivo principal es minimizar el coste total de operación de la microrred en un entorno estocástico, al considerar el error en la predicción de la demanda, garantizando la operación confiable en isla de la microrred. El problema se formula como MILNP.

En la Figura 3.1 se muestra el procedimiento propuesto en esta Tesis para el diseño de un EMS para una microrred integrada por dos unidades de generación convencionales (MT y DE), dos RESs (PV y WT) y un sistema de almacenamiento de energía por baterías (BESS), utilizando la PHUGyA. El problema se aborda en tres etapas:

- En la primera etapa, dada una serie temporal de datos de demanda, se aplica un Modelo Autorregresivo de Media Móvil (ARMA), para predecir la curva de demanda de la microrred en estudio, en un horizonte de programación horaria de 24 horas en adelante.

En esta fase además, se obtiene el error en el pronóstico de la demanda.

Se ha usado sólo para la demanda, pero se puede extender a la predicción de la irradiancia solar y la velocidad del viento para obtener la potencia de las fuentes de energía renovables.

- En la segunda etapa, se determina la Asignación de las Unidades Generadoras (UC) que participarán en el cubrimiento de la demanda en un entorno estocástico, en este caso, (MT, DE, BESS).

En este trabajo se asume que la reserva rodante tanto a subir como a bajar, aportadas por las unidades de generación convencionales (MT y DE) y el sistema de almacenamiento de energía eléctrica por baterías (BESS), debe ser capaz de cubrir el error en la predicción de la demanda, obtenido en la etapa anterior.

La condición anterior, asegura la operación confiable en isla de la microrred. Por tal motivo, se incorpora al problema de optimización criterios de confiabilidad que garanticen dicha condición.

- En la tercera etapa, se modela la operación en tiempo real de la microrred, donde se observa que la predicción de la demanda no coincide con el valor real, originando un nuevo valor de reserva rodante (ω_t).

Entonces, se resuelve un segundo problema de optimización en el que, una vez conocido los generadores que están encendidos, se decide cuál o cuales de ellos van a hacer frente a esta variación en la demanda, de tal manera que se minimicen los costes de operación (ED).

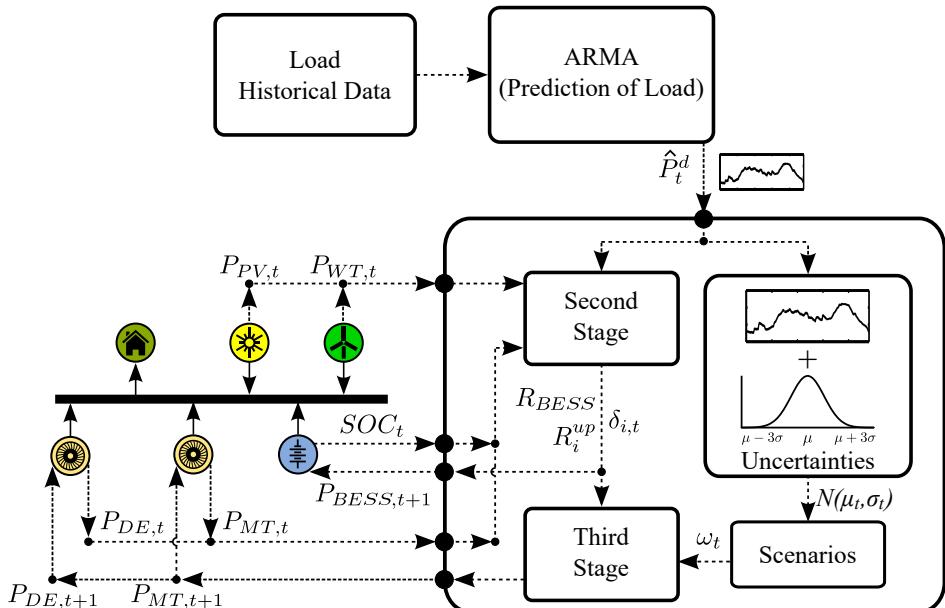


Figura 3.1 Diagrama de flujo del problema de la Programación Horaria de las Unidades de Generación y Almacenamiento en un entorno estocástico, extraída de [1].

3.3 Modelado del sistema

3.3.1 Modelado de las incertidumbres y predicción de la demanda

Los datos históricos de la demanda forman una serie temporal de datos que se puede usar para predecir la demanda eléctrica futura en una microrred (ver por ejemplo [102] y [103]).

El modelo ARMA es una combinación de un modelo autorregresivo (AR) de p términos y un modelo de media móvil (MA) de q términos, utilizados para predecir el comportamiento futuro de una señal y_t en función de los datos históricos, y se formula de la siguiente manera:

$$y(t) = \sum_{i=1}^p \Phi_i y_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j} \quad (3.1)$$

donde Φ_i son los coeficientes del modelo autorregresivo, θ_j son los coeficientes del término promedio móvil, ε_{t-j} son los errores de predicción, que se ajustan por el promedio de la función de distribución normal y la desviación estándar de la muestra, y $y(t)$ es la señal a estimar. Este modelo sugiere que el valor $y(t)$ para cualquier punto en la serie temporal es una combinación lineal de los valores anteriores p de la demanda y de los valores previos q de los errores.

En este estudio, se han utilizado datos históricos de demanda de dos años para obtener los coeficientes en (3.1). Para fijar los valores de p y q , se ha utilizado un criterio basado en la información estadística, en este caso, el Criterio de información de Akaike (*Akaike Information Criterion, AIC*) [102]. Los valores obtenidos para estos parámetros son $p = 6$ y $q = 5$. Por tanto, se concluye que la serie temporal de la demanda de la microrred puede ser modelada y, aún más, predecir futuros valores de la serie mediante el modelo ARMA(6,5).

El resultado de la aplicación de este algoritmo es la predicción de la demanda de la microrred para las próximas 24 horas, Figura 3.3. Para conocer la precisión del método, se ejecutan algunas simulaciones y el resultado se compara con datos históricos de demanda conocidos. Por lo tanto, se puede definir $e_{DM,t}$ como el error en el pronóstico de la demanda, el cual es calculado por la siguiente expresión:

$$e_{DM,t} = \frac{\text{Valor estimado} - \text{valor real}}{\text{valor estimado}} \times 100 \quad (3.2)$$

En este trabajo, se asume que los errores en la predicción de la demanda cada hora pueden ser modelados como variables aleatorias distribuidas normalmente. Por lo que el error de pronóstico de demanda neto cada hora también sigue una distribución normal ($e_{DM,t} \sim \mathcal{N}(\mu_t, \sigma_t)$), con media (μ_t) igual a cero y desviación estándar (σ_t).

Esto permite plantear que la potencia real demanda (P_t^d) por la microrred en cualquier instante de tiempo t será:

$$P_t^d = \hat{P}_t^d + e_{DM,t}, \quad (3.3)$$

donde: (\hat{P}_t^d) es la potencia de demanda estimada por la microrred en cada momento t y $e_{DM,t}$, es el error estimado en la predicción de la demanda en el instante t .

Por tanto, se puede decir que la potencia real demandada tomará una valor en cualquier instante de tiempo t en el intervalo $[\hat{P}_t^d + \mu_t - \sigma_t, \hat{P}_t^d + \mu_t + \sigma_t]$.

Según la Figura 3.2, es necesario señalar que, para la distribución normal $\mathcal{N}(\mu_t, \sigma_t)$, los valores inferiores a una desviación estándar, σ_t , de distancia de la media, μ_t , representan el 68,27 % del conjunto, mientras que dos y tres desviaciones estándar de distancia de la media, μ_t , representan el 95,45 % y el 99,73 % del conjunto, respectivamente [104].

Entonces se puede decir, que los valores de la potencia real demandada (P_t^d) se pueden encontrar dentro de bandas con semiancho de una, dos y tres veces la desviación típica a la media, $[\hat{P}_t^d + \mu_t - n_r \sigma_t, \hat{P}_t^d + \mu_t + n_r \sigma_t]$.

Basado en la regla general de tres veces la desviación estándar, $(3\sigma_t)$ [105], se puede considerar que el error en la estimación de la demanda ($e_{DM,t}$) se encuentra en

una banda definida por $[\mu_t - 3\sigma_t, \mu_t + 3\sigma_t]$. Por tanto, se puede afirmar que la potencia demandada en la microrred en un instante t se encuentra en el intervalo definido por $[\hat{P}_t^d + \mu_t - 3\sigma_t, \hat{P}_t^d + \mu_t + 3\sigma_t]$.

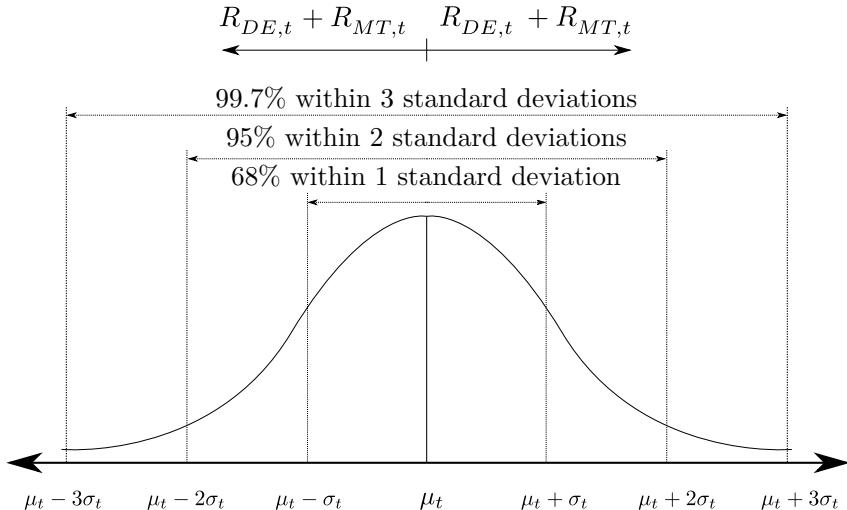


Figura 3.2 Distribución de probabilidad del error de estimación de demanda alrededor de la media, extraída de [2].

Los resultados de las simulaciones se muestran en la Figura 3.3, donde se representa un caso de 24 horas, junto con el valor máximo y mínimo para el pronóstico de demanda obtenido después de aplicar el criterio $3\sigma_t$.

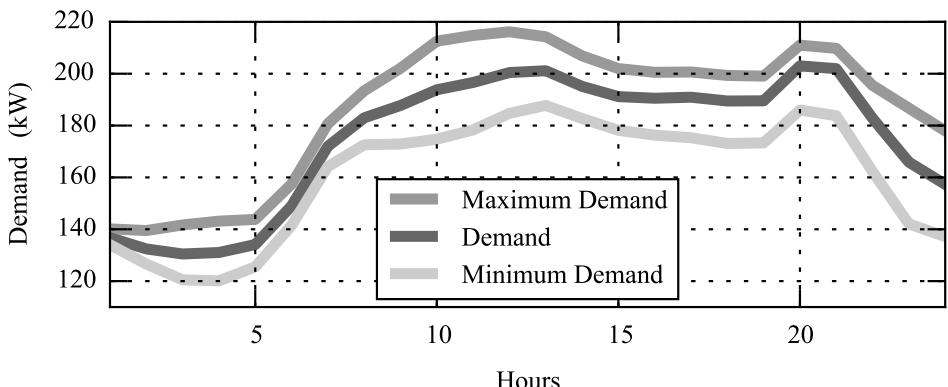


Figura 3.3 Demanda de la microrred, con intervalos de confianza según el criterio 3σ , extraída de [1].

Esto significa que, según la formulación del problema presentado en la Sección 3.2,

para garantizar que la microrred pueda operar de forma aislada en tiempo real debe dar respuesta a la variación entre la potencia estimada y la real demanda en cada instante de tiempo t provocada por el error en la predicción de la demanda. En este trabajo se asume que para lograr este objetivo la microrred debe disponer de suficiente reserva, tanto a subir como a bajar, aportada por las unidades de generación controlables (MT y DE) y el BESS.

Dado que se espera que el funcionamiento óptimo de los generadores se acerque a los valores nominales, se puede abordar con éxito una variación eventual de la demanda, considerando que el sistema de almacenamiento de energía por baterías (BESS) es responsable también de cubrir esa variación, en caso de que la reserva de los generadores controlables no sea suficiente.

3.3.2 Generador Fotovoltaico (PV)

Un generador fotovoltaico consiste en un conjunto de paneles o módulos fotovoltaicos conectados entre ellos para proveer potencia a uno o más inversores fotovoltaicos. Estos inversores transforman la energía de corriente continua recibida del generador fotovoltaico en corriente alterna, la que finalmente se entrega a la red. La potencia producida por una planta fotovoltaica (PV) depende de varios factores, tales como: la irradiación solar, la temperatura ambiente, la temperatura de la celda solar y la degradación de los módulos. La potencia generada por esta clase de sistema está directamente relacionada con el punto de operación de los módulos. Este punto de operación lo fija el inversor de potencia usando un seguimiento del punto de potencia máximo (MPPT). De esa forma el sistema siempre opera suministrando la cantidad máxima de potencia disponible en la fuente.

A continuación se muestra el modelo simplificado que se utiliza en este trabajo, presentado en [106]:

$$P_{PV,t} = P_{STC} \frac{n \cdot E_{M,t}}{E_{STC}} [1 + k(T_{M,t} - T_{STC})], \quad \forall t, \quad (3.4)$$

donde:

$P_{PV,t}$: potencia que entrega la planta PV en el instante t ,

$E_{M,t}$: irradiancia solar en el instante t ,

P_{STC} , E_{STC} , T_{STC} : potencia máxima, irradiancia, y temperatura en condiciones estándar de prueba (STC). Estos valores corresponden a una temperatura de la celda de 25°C y con una irradiancia de 1000W/m^2 con una masa de 1,5.

n : número de paneles solares PV,

k : coeficiente de temperatura de potencia ($\%/{}^{\circ}\text{C}$) y

$T_{M,t}$: temperatura del módulo en el instante t y se puede calcular con la expresión siguiente:

$T_{M,t} = T_{amb} + \epsilon_{PV} \frac{E_{M,t}}{E_{STC}}$, donde: T_{amb} es la temperatura ambiente (${}^{\circ}\text{C}$) y ϵ_{PV} es una constante del módulo que proporciona el fabricante.

3.3.3 Turbina eólica (WT)

Existen muchos artículos que tratan sobre el modelo y la simulación de turbinas eólicas [107, 108]. La mayoría de estos modelos tienen un gran nivel de detalles y se utilizan

además en el análisis de la estabilidad (ver por ejemplo, [109]). Para este estudio se utiliza el siguiente modelo simplificado del generador

$$P_{WT,t} = \begin{cases} 0 & \text{for } v < v_{ci}, \\ P_r \frac{v^3 - v_{ci}^3}{v_r^3 - v_{ci}^3} & \text{for } v_{ci} < v < v_r, \\ P_r & \text{for } v_r < v < v_{co}, \\ 0 & \text{for } v > v_{co}, \end{cases} \quad \forall t, \quad (3.5)$$

donde:

P_r : Potencia nominal (kW),

v_r : Velocidad nominal del viento (m/s),

v_{ci} : Velocidad de corte (límite inferior) en (m/s),

v_{co} : Velocidad de corte (límite superior) en (m/s),

v : Velocidad real del viento en (m/s) .

Para una información más detallada acerca del modelo referirse a [110].

3.3.4 Generador Diesel (DE)

Actualmente el DE es uno de los tipos de tecnología más comunes de generación y de mayor uso en las microrredes. El coste de operación (combustible) de un sistema de potencia se puede expresar como una función de la potencia activa de entrega y usualmente se modela como un polinomio cuadrático y que se expresa de la siguiente forma

$$C_{DE,t} = d_{DE} + e_{DE} P_{DE,t} + f_{DE} P_{DE,t}^2, \quad \forall t, \quad (3.6)$$

donde:

$C_{DE,t}$: coste total de combustible (\mathbb{E}/h) en el instante t ,

$P_{DE,t}$: potencia del generador en el instante t y,

d_{DE} (\mathbb{E}/h), e_{DE} (\mathbb{E}/kWh) y f_{DE} (\mathbb{E}/kW^2h): parámetros especificados por el fabricante [111] y que dependen fuertemente del tipo de motor, generador y combustible.

Adicionalmente, P_{DE}^{min} y P_{DE}^{max} son la potencia mínima y máxima que el DE puede suministrar en cada instante de tiempo t . Entonces:

$$P_{DE}^{min} \leq P_{DE,t} \leq P_{DE}^{max}. \quad (3.7)$$

3.3.5 Microturbina (MT)

El modelo de la microturbina (MT) es similar al modelo del generador diesel (DE). En este caso los parámetros de la curva de operación se adaptan al comportamiento y eficiencia del modelo de la MT [112]. De modo que el coste de operación se puede expresar como:

$$C_{MT,t} = d_{MT} + e_{MT} P_{DE,t} + f_{MT} P_{MT,t}^2, \quad \forall t, \quad (3.8)$$

donde:

$C_{MT,t}$: coste total del gas (\mathbb{E}/h) en el instante de tiempo t ,

$P_{MT,t}$: potencia de generador en el instante de tiempo t y

$d_{MT}(l/h)$, $e_{MT}(kW l/h)$ y $f_{MT}(kW^2 l/h)$: parámetros especificados por el fabricante [111], [112] y que dependen fuertemente del tipo de turbina, generador y coste de gas.

Las curvas de coste de operación del DE y la MT en función de la potencia dada se muestran en la Figura 3.6.

De manera similar al caso de DE, la potencia que entrega la MT está limitada físicamente:

$$P_{MT}^{min} \leq P_{MT,t} \leq P_{MT}^{max}, \quad (3.9)$$

donde:

P_{MT}^{min} y P_{MT}^{max} son la potencia mínima y máxima que la MT puede suministrar en cada instante de tiempo t .

3.3.6 Balance de Potencia

A diferencia de otros enfoques para el mismo problema como en [39], en este trabajo se considera una microrred que opera en el caso más desfavorable, funcionamiento aislado, es decir, no tiene conexión con la red de distribución. Este hecho implica que la potencia demandada por los consumidores debe ser suministrada localmente por los recursos de generación y almacenamiento distribuidos en la microrred. Por tanto el balance de potencia debe cumplirse en cada instante de tiempo t .

La Figura 3.1 muestra que, inicialmente la potencia total generada por todos los generadores (MT, DE, WT, PV) y la potencia generada o consumida por el sistema de almacenamiento por batería (BESS) debe ser igual a la potencia de demanda estimada por la microrred en cada momento t (\hat{P}_t^d).

$$\hat{P}_t^d = P_{MT,t} + P_{DE,t} + P_{WT,t} + P_{PV,t} + P_{BESS,t} \quad \forall t. \quad (3.10)$$

Es necesario recordar que la potencia real demandada (P_t^d) en cualquier instante de tiempo t está condicionada por la potencia demanda estimada (\hat{P}_t^d) y el error obtenido en dicho pronóstico ($e_{DM,t}$), la cual está expresada en la ecuación (3.3). Por tal motivo se cumple que:

$$P_t^d = P_{PV,t} + P_{WT,t} + P_{DE,t} + P_{MT,t} + P_{BESS,t}, \quad \forall t. \quad (3.11)$$

Es importante señalar que, en la Sección 3.2, se planteo que al considerar las incertidumbres en el pronóstico de la demanda, el error de estimación ($e_{DM,t}$) debe tenerse en cuenta en el problema para garantizar la confiabilidad de la solución provista. Esta fiabilidad se cumple con un adecuado dimensionamiento de la reserva rodante.

3.3.7 Límites de Generación

La potencia generada por las unidades generadoras despachables (MT y DE) están físicamente limitadas. Es decir, la generación de cada unidad debe estar dentro de los siguientes límites.

$$P_{min_{DE}} \delta_{DE,t} \leq P_{DE,t} \leq P_{max_{DE}} \delta_{DE,t}, \quad (3.12)$$

$$P_{\min_{MT}} \delta_{MT,t} \leq P_{MT,t} \leq P_{\max_{MT}} \delta_{MT,t}, \quad (3.13)$$

donde P_{\min_i} y P_{\max_i} definen la potencia mínima y máxima que puede entregar el generador i , respectivamente y $\delta_{i,t}$ es una variable binaria que especifica la condición de apagado ($\delta_{i,t} = 0$) y encendido ($\delta_{i,t} = 1$) de las unidades generadoras despachables.

3.3.8 Sistema de almacenamiento de energía por baterías (BESS)

Las baterías son dispositivos electroquímicos que almacenan energía desde otras fuentes de energía de corriente alterna (CA) o corriente directa (CD) para usarse posteriormente [112]. Las baterías permiten a la microrred cubrir la demanda pico y almacenar excesos de generación debido a su rápida respuesta. Un conjunto de baterías forman un sistema de almacenamiento de energía (BESS), que se caracterizan por tres parámetros.

1. Capacidad: es la cantidad de carga eléctrica que el BESS puede producir a voltaje nominal.
2. Velocidad de carga máxima: es una medida de la velocidad a la cual una batería se puede cargar.
3. Velocidad máxima de descarga: es una medida de la velocidad a la que se puede descargar una batería.

La $P_{BESS,t}$ es la potencia demandada o suministrada por el BESS en el instante t . Este valor puede ser positivo o negativo:

- Si $P_{BESS,t} > 0$, el BESS suministra potencia a la microrred, actuando como un generador adicional. En este caso el BESS se descarga.
- Cuando $P_{BESS,t} < 0$, el BESS absorbe potencia de la microrred, se comporta como una carga. En este caso el BESS se carga.

La gestión del sistema sistema de almacenamiento por baterías (BESS) tiene varias restricciones asociadas:

- Primero: la potencia entregada o recibida por el BESS está físicamente limitada como sucede con el resto de las unidades generadoras despachables. Por tanto:

$$P_{BESS,t} \leq P_{BESS}^{\max}, \quad (3.14)$$

$$P_{BESS,t} \geq P_{BESS}^{\min}. \quad (3.15)$$

- Segundo: se define el SOC_t como el estado de carga del BESS en el instante t . De acuerdo con la energía almacenada en la batería el SOC_t tomará diferentes valores. Dos restricciones se deben tomar en consideración cuando se trata con el estado de carga del BESS. El SOC_t debe tener un valor que se encuentre en una banda limitada

por la capacidad de la batería y el estado de carga con el valor mínimo admisible. Eso es:

$$SOC^{min} \leq SOC_t \leq SOC^{max}, \quad \forall t, \quad (3.16)$$

donde SOC^{min} y SOC^{max} son los valores mínimos y máximos para el estado de carga de la batería (SOC_t), respectivamente. Adicionalmente es importante puntualizar que la batería es un sistema dinámico, esto es, el estado de carga del BESS depende de los flujos de potencia a través de sus terminales, Por tanto,:;

$$SOC_{t+1} = SOC_t - \begin{cases} P_{BESS,t} \Delta t \eta_c & \text{si } P_{BESS,t} < 0 \\ \frac{P_{BESS,t} \Delta t}{\eta_d} & \text{si } P_{BESS,t} > 0 \end{cases}, \quad \forall t, \quad (3.17)$$

donde:

η_c y η_d : eficiencia de carga y descarga respectivamente y,
 Δt : tiempo entre muestras.

Recordar que cuando $P_{BESS,t} > 0$ el BESS se está descargando, el SOC_{t+1} decrece. Inversamente cuando $P_{BESS,t} < 0$ el BESS se está cargando, el SOC_{t+1} aumenta de valor.

3.3.9 Reserva rodante

La reserva rodante (*spinning reserve, SR*) es la capacidad no utilizada del sistema de energía para responder voluntariamente a contingencias dentro de un período de tiempo dado usando dispositivos ya sincronizados a red [113]. Es un recurso importante que puede salvaguardar los sistemas de energía sin desprendimiento involuntario de carga. El aumento del requisito de SR puede reducir la probabilidad y la gravedad de la pérdida de carga [114]. Sin embargo, proporcionar SR tiene un coste. Este coste está asociado al aumento de consumo de combustible de las unidades de generación despachables, originado por la necesidad de aumentar la generación de potencia de estas unidades, para dar respuesta a incrementos de la carga en un instante de tiempo t [115, 116].

Se han propuesto muchos métodos para determinar el requisito de SR en grandes sistemas de energía, pero normalmente se utilizan dos criterios. Uno es utilizando reglas deterministas, mediante el cual la reserva se selecciona igual a alguna fracción de la carga pico o igual a la capacidad de la unidad generadora más grande en línea o una combinación de ambos [117]. Otro es usando enfoques probabilísticos, para ello, incorporan restricciones de confiabilidad al problema de optimización, como por ejemplo, que la probabilidad de perdida de carga y/o la energía esperada no suministrada, esté por debajo de un umbral predefinido [118, 119, 120, 121].

No es sencillo estimar el requisito de SR en microrredes. La flexibilidad y la facilidad de las microrredes para proporcionar SR dependen de la combinación de diferentes fuentes de energía. Siendo necesario precisar que los RESs (PV y WT) introducen incertidumbres significativas en la entrega de potencia. Por tanto, la SR puede ser aportada por las unidades de generación despachables (MT y DE) y los sistemas de almacenamiento de energía (BESS).

La reserva rodante define la cantidad de potencia disponible en el generador para un punto operativo dado. Es decir, si el generador proporciona $P_{i,t}$ la reserva rodante $R_{i,t}^{up}$, se define como:

$$R_{i,t}^{up} = P_{max_i} - P_{i,t} \geq 0, \quad (3.18)$$

donde i denota la unidad de generación correspondiente. Se debe tener en cuenta que solo las unidades generadoras despachables y el sistema de almacenamiento de energía proporcionan reserva rodante.

Se denota $R_{DE,t}$ y $R_{MT,t}$ como reserva rodante de las unidades DE y MT en el instante t , respectivamente. Estos parámetros se definen matemáticamente como sigue:

$$R_{DE,t} = P_{DE}^{max} - P_{DE,t}, \quad (3.19)$$

$$R_{MT,t} = P_{MT}^{max} - P_{MT,t}. \quad (3.20)$$

Por tanto, la suma de las reservas rodante de los dos generadores mencionados anteriormente (DE, MT) y el aporte del banco de baterías (BESS) constituyen la reserva rodante total de la microrred en el momento t , R_t^{up} :

$$R_t^{up} = R_{DE,t}^{up} + R_{MT,t}^{up} + R_{BESS,t}^{up}, \quad \forall t, \quad (3.21)$$

Análogamente, $R_{i,t}^{down}$, se define como la diferencia entre la potencia generada por la unidad i en el instante t y la potencia mínima que el generador puede producir.

$$R_{i,t}^{down} = P_{i,t} - P_{min_i} \geq 0, \quad (3.22)$$

$$R_t^{down} = R_{DE,t}^{down} + R_{MT,t}^{down} + R_{BESS,t}^{down} \quad \forall t, \quad (3.23)$$

En esta Tesis, se propone un método probabilístico para estimar el requerimiento de la SR para la PHUGyA. El requisito óptimo de SR está determinado por un criterio de confiabilidad, basado en la regla general de tres desviaciones estándar (σ_t) de la media (μ_t). Para satisfacer el criterio de $3\sigma_t$, se impone que la reserva rodante, tanto ascendente como descendente, debe cubrir el error de estimación de la demanda en el 99.73 % de los casos:

$$R_t^{up} \geq 3\sigma_t \quad \forall t, \quad (3.24)$$

$$R_t^{down} \geq 3\sigma_t \quad \forall t, \quad (3.25)$$

3.3.10 Otros Costes

3.3.10.1 Coste de operación y mantenimiento de las unidades despachables (DE y MT).

Los costes de operación y mantenimiento de cada unidad generadora despachable, se consideran que son proporcionales a la potencia producida [122], [112]:

$$C_{OM_{DE}} = k_{OM_{DE}} \sum_{\forall t} P_{DE,t}, \quad \forall t, \quad (3.26)$$

$$C_{OM_{MT}} = k_{OM_{MT}} \sum_{\forall t} P_{MT,t}, \quad \forall t. \quad (3.27)$$

donde:

$k_{OM_{DE}}$ (€/kW h): coste de mantenimiento DE,

$k_{OM_{MT}}$ (€/kW h): Coste de mantenimiento MT.

3.3.10.2 Coste de arranque de las unidades despachables (DE and MT)

El coste de arranque de una unidad generadora depende del tiempo que la unidad haya estado parada antes de arrancar [123]. Por tanto el coste de arranque en cualquier instante se puede estimar como [124]:

$$C_{SU_{DE}} = a_{DE} + b_{DE} \left[1 - \exp \left(\frac{-T_{DE,OFF}}{c_{DE}} \right) \right], \quad (3.28)$$

$$C_{SU_{MT}} = a_{MT} + b_{MT} \left[1 - \exp \left(\frac{-T_{MT,OFF}}{c_{MT}} \right) \right], \quad (3.29)$$

donde:

a_{DE}, a_{MT} (€): coste de arranque de la unidades generadoras diesel y microturbina desde el estado en caliente,

b_{DE}, b_{MT} (€): coste de arranque de las unidades generadoras diesel y microturbina desde el estado en frío,

c_{DE}, c_{MT} (€): constantes de tiempo de enfriamiento de las unidades generadoras diesel y microturbina y,

$T_{DE,OFF}$ y $T_{MT,OFF}$ representa el tiempo que cada unidad generadora ha estado desconectada.

3.3.10.3 Coste de Emisiones

El coste de los factores medioambientales externos (producción de los contaminantes CO₂, SO₂ or NO_x) se considera que es una función lineal de la potencia de salida [39]:

$$CEM_{DE} = \sum_{k=1}^{Nem} \sum_{\forall t} \alpha_k \beta_{DE,k} P_{DE,t}, \quad \forall t, \quad (3.30)$$

$$CEM_{MT} = \sum_{k=1}^{Nem} \sum_{\forall t} \alpha_k \beta_{MT,k} P_{MT,t}, \quad \forall t, \quad (3.31)$$

donde:

Nem : indicador del tipo de emisión,

α_k : costes externos del tipo de emisión k ($\text{€}/\text{kg}$),

$\beta_{DE,k}$ y $\beta_{MT,k}$: factores de emisión de las unidades generadoras despachables y el tipo de emisión k en ($\text{€}/\text{kW h}$).

3.4 Estructura y datos de la microrred estudiada

En este apartado se presenta la estructura de la microrred. Además se informa sobre los datos técnicos de las unidades generadoras y del sistema de almacenamiento de energía por baterías que conforman este sistema de energía, así como los coeficientes de costes de combustible, de reserva rodante, de arranque y paradas y de emisiones de gases de efecto invernadero asociados a las unidades de generación controlables. Esta información será utilizada para validar los algoritmos que se presentan en el Capítulo 4.

3.4.1 Estructura de la microrred

En particular, en este trabajo se ha considerado una microrred como la mostrada en la Figura 3.4. Así, la microrred en estudio está compuesta por un generador diésel (DE) y una microturbina (MT) como unidades controlables, y una turbina eólica (WT) y una planta fotovoltaica (PV) como fuentes de energía renovables no controlables (RES). Por último, se considera un Sistema de Almacenamiento de Energía por Baterías (BESS) integrado por baterías de tecnología iones de litio.

Para este estudio, se considera que las potencias generadas por los recursos renovables (PV y WT) tienen una única predicción, la más probable, proporcionada por organismos externos. Sin embargo, la potencia generada por las unidades despachables (DE y MT) son variables de nuestro problema, así como la gestión del BESS. Por lo tanto, el problema de la programación horaria de las unidades de generación permite obtener qué unidad de despacho se conectará a la microrred y la potencia que entregará en cada momento t .

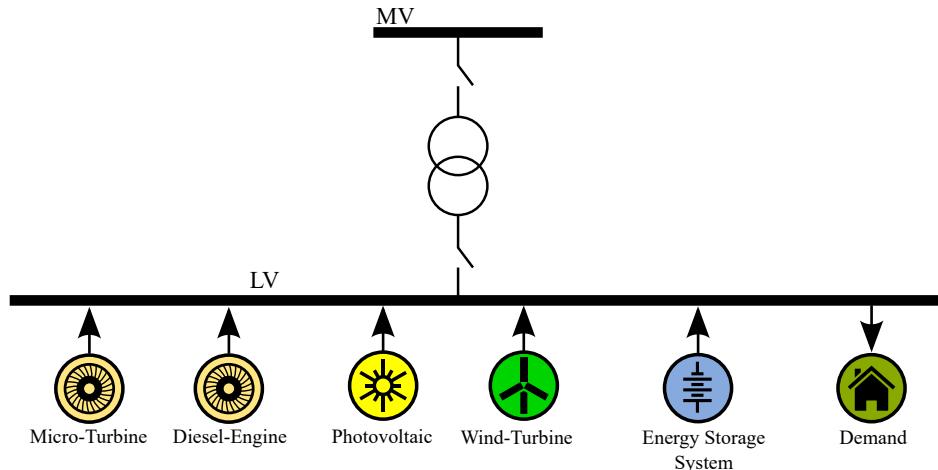


Figura 3.4 Estructura de la microrred considerada en el problema, extraída de [1].

3.4.2 Datos de la microrred

3.4.2.1 Datos utilizados para validar el algoritmo 1

Los parámetros nominales de potencia de las unidades de generación controlables (MT y DE), de las fuentes de energía renovable (PV y DE) y del sistema de almacenamiento de energía por batería (BESS) se muestran en la Tabla 3.1.

Tabla 3.1 Datos técnicos de las unidades generadoras [3].

Sources	P_{min} (kW)	P_{max} (kW)	SOC_{min} (kWh)	SOC_{max} (kWh)	η_c	η_d	P_{max}^c (kW)	P_{max}^d (kW)
Microturbine	5	20	-	-	-	-	-	-
Diesel	15	150	-	-	-	-	-	-
PW	50	80	-	-	-	-	-	-
PV	0	40	-	-	-	-	-	-
BESS	-	-	70	280	0,9	0,9	120	120

La Tabla 3.2 muestra los coeficientes de coste de combustible de las unidades de generación controlables (MT y DE).

Tabla 3.2 Coeficientes de costes de las unidades generadoras [3].

DDG	coeficientes de costes		
	a (\$)	b (\$/kW)	c (\$/kW ²)
Microturbine	2,62	0,15	0,15
Diesel	0,6	0,05	0,02

El coste de capacidad de reserva rodante, tanto a subir como a bajar de la MT y DE, se supone un 30 % del coste incremental mas alto de producción total de energía [125].

Finalmente, las Figuras 3.5 y 3.3 muestran, respectivamente, los perfiles de potencia de los generadores de energía renovable y la demanda real y prevista 24 horas en adelante.

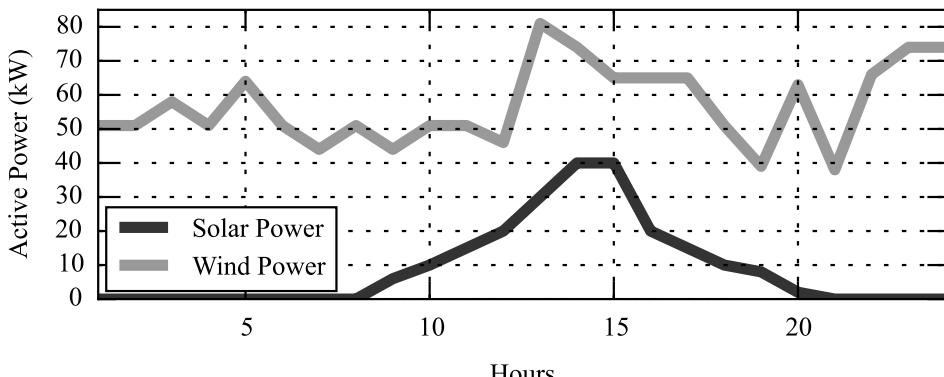


Figura 3.5 Potencia de las unidades solar (PV) y eólica (WT) durante 24 horas, extraída de [1].

3.4.2.2 Datos utilizados para validar el algoritmo 2

La microrred utilizada para este caso de estudio, tiene la misma configuración que la empleada para el caso de estudio 1, Figura 3.4. En la Tabla 3.3 se muestran los parámetros nominales de las fuentes de generación, conjuntamente con los costes de operación, de arranque y los coeficientes de costes de mantenimiento de las mismas.

Tabla 3.3 Parámetros característicos de cada una de las unidades componentes de la microrred, extraída de [2].

i	P_i^{\min} (kW)	P_i^{\max} (kW)	d_i (€/h)	e_i (€/kWh)	f_i (€/kW ² h)
DE	5	80	1.9250	0.2455	0.0012
MT	20	140	7.4344	0.2015	0.0002
i	a_i (€)	b_i (€)	c_i (€)	K_{OM_i} (€/kWh)	
DE	0.3	0.4	5.2	0.01258	
MT	0.4	0.28	7.1	0.00587	

En la figura 3.6 se muestran las gráficas correspondientes a los costes de operación de las unidades despáchales. Se observa que para valores de potencia inferiores a 55 kW es más barato la generación en las unidades DE que en las MT. Así mismo se observa en la tabla 3.4 que la contaminación es mayor con la DE que con la MT. Por tanto cuando la potencia dada por los generadores aumenta significativamente, la solución con MT es más baja en emisiones y más barata. Esto hace que la función de coste en las ecuaciones (4.8) y (4.9) tiene un valor mínimo en dos puntos diferentes de operación.

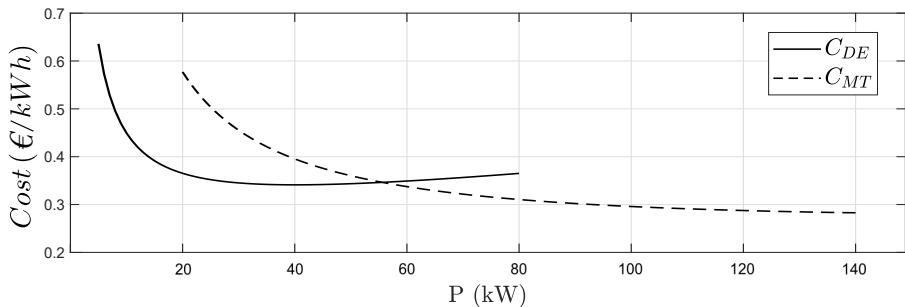


Figura 3.6 Coste de operación de los generadores diesel (DE) y microturbina (MT) en términos de suministro de potencia, extraída de [2].

En la figura 3.7, se muestran los costes de arranque de ambas unidades despachables respecto al tiempo que han permanecido desconectadas. Como se observa el coste del arranque desde el estado en frío es más alto en MT que en DE; sin embargo después de las 5 h es más barato en la MT.

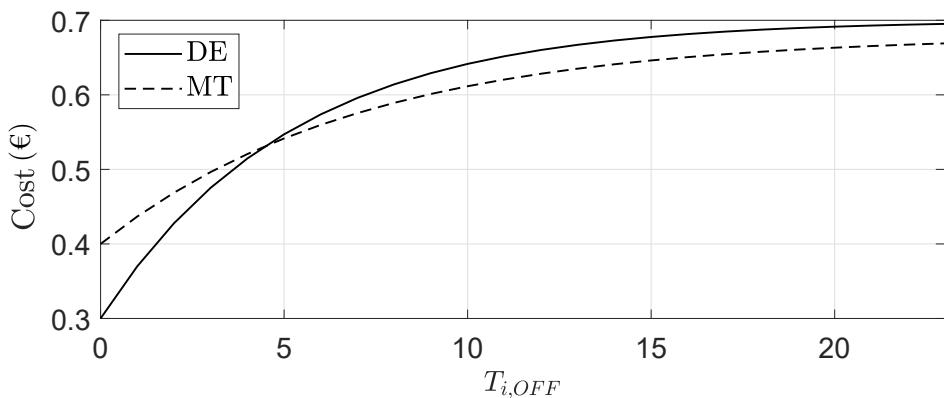


Figura 3.7 Costes de arranque de las unidades despachables en términos del tiempo que ha estado apagada, extraída de [2].

En la tabla 3.4 se muestran los coeficientes de costes correspondientes a MT y DE para tres tipos de emisiones consideradas, CO_2 , SO_2 y NO_x . Estos datos se utilizan en las ecuaciones (3.30) y (3.31).

Tabla 3.4 Costes de los factores externos y de emisión de la generación de la red principal, extraída de [2].

Emission Type	α_k	$\beta_{DE,k}$	$\beta_{MT,k}$
CO_2	0.0275	0.6495	0.7239
SO_2	1.9475	0.2059	0.0036
NO_x	8.2625	9.8883	0.1995

En la tabla 3.5 se muestran los parámetros del BESS.

Tabla 3.5 Parámetros característicos del Sistemas de Almacenamiento de Energía por Batería (BESS), extraída de [2].

$SOC^{min} (kWh)$	$SOC^{max} (kWh)$	$P_{ESS}^{min} (kW)$	$P_{ESS}^{max} (kW)$	η_c	η_d
70	280	-120	120	0.9	0.9

En la Figura 3.8 se muestran las curvas correspondientes a la potencia de la demanda y la generación de las fuentes renovables (PV, WT) para el período de 24 h. El problema se resolvió considerando un dato por hora. Es importante destacar que este tiempo puede ser reducido, lo que implica un incremento del número de variables del problema pero preservando el planteamiento del problema que se hace en ese trabajo.

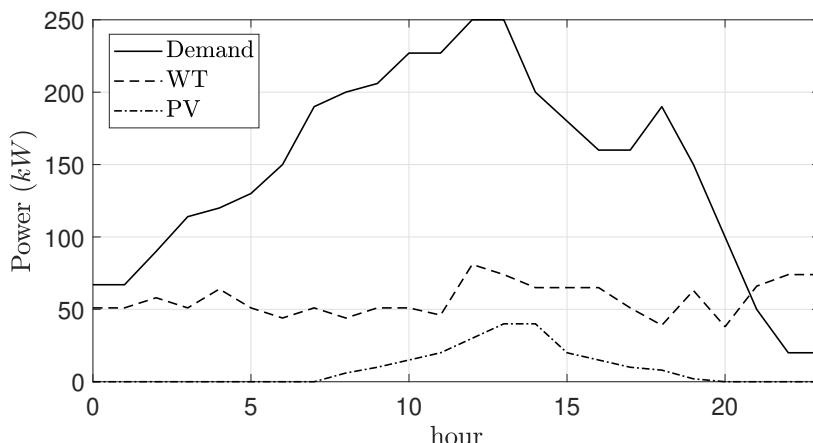


Figura 3.8 Gráfica de demanda de potencia y de generación de las fuentes renovables, extraída de [2].

4 Algoritmos propuestos

4.1 Introducción

Este capítulo muestra el diseño de un Sistema de Gestión de Energía (EMS) para microrredes. Se considera que estos sistemas de energía operan en el caso más desfavorable, el funcionamiento confiable en isla. El EMS utiliza la herramienta de Programación Horaria de las Unidades de Generación y Almacenamiento (PHUGyA), conocido como *Unit Commitment* (UC), para realizar la programación horaria a corto plazo, 24 horas en adelante, de las unidades de generación controlables para dar respuesta a la demanda de la microrred.

El problema de la PHUGyA en microrredes se formula matemáticamente como un problema de programación no lineal entero mixta (MILNP). Se proponen dos algoritmos de solución a este problema. El primero, utiliza un enfoque clásico basado en MILP y el segundo propone una técnica de optimización con un enfoque metaheurístico, en este caso un algoritmo genético (GA). Ambos algoritmos se validan en una microrred integrada por dos generadores controlables (DE y MT) dos RESs (MT y PV) y un BESS. Finalmente se presentan los resultados de las simulaciones.

4.2 Enfoque de Programación Lineal Entera Mixta

4.2.1 Introducción

Esta sección muestra el primer algoritmo desarrollado para resolver el problema de la PHUGyA de una microrred, con capacidad para operar en modo isla y cuya estructura y datos se muestran en el Capítulo 3, Sección 3.4. El problema de optimización propone una función objetivo para minimizar el coste total de operación de la microrred que incluye el coste de generación y el coste de reserva rodante asociados a las unidades de generación controlables. Las variables de decisión incluyen el estado de encendido/apagado ($\delta_{i,t}$), la potencia de salida de las unidades de generación controlables ($P_{i,t}$), el estado de carga/descarga de energía del BESS (SOC_t), así como la reserva rodante a subir ($R_{i,t}^{up}$) y a bajar ($R_{i,t}^{down}$) proporcionada por las unidades de generación controlables y el BESS.

La función objetivo se modela como MILNP. El carácter no lineal lo aporta la función de coste de combustible asociadas a las unidades de generación controlables, la cual tiene una relación cuadrática con la potencia. Las restricciones que se introducen en el problema de optimización son lineales y todas las variables son reales, las que indican el encendido o apagado de las unidades de generación convencionales son enteras (las cuales se consideran binarias). Para resolver este problema se ha utilizado la función de Matlab *quadprog* que resuelve problemas de programación cuadrática (QP) con restricciones lineales. Para su solución convierte el problema en sucesivos problemas de MILP.

4.2.2 Formulación del problema

El problema se aborda en tres etapas:

- En la primera etapa, se utiliza el modelo ARMA, para predecir la curva de demanda de la microrred. Como se mencionó en la Sección 3.3.1, se asume que los errores en la predicción de la demanda cada hora pueden ser modelados como variables aleatorias distribuidas normalmente, por lo que el error de pronóstico de demanda neto cada hora también sigue una distribución normal ($\epsilon \sim N(\mu_t, \sigma_t)$). Basado en la regla general de $3\sigma_t$, se puede considerar que el error en la estimación de la demanda se encuentra en una banda definida por $[\mu_t - 3\sigma_t, \mu_t + 3\sigma_t]$. Por tanto, se puede afirmar que la potencia demandada en la microrred en un instante t se encuentra en el intervalo definido por $[\hat{P}_t^d + \mu_t - 3\sigma_t, \hat{P}_t^d + \mu_t + 3\sigma_t]$.

A partir de estos resultados, en este trabajo se considera que la probabilidad de que una microrred opere exitosamente en isla, es cuando disponga suficiente reserva rodante, tanto ascendente como descendente, para satisfacer la demanda estimada (\hat{P}_t^d) en cada instante t . Esto significa que la reserva rodante, tanto hacia arriba como hacia abajo, debe cubrir el error en la estimación de la demanda en un 99,73 %.

- En la segunda etapa, se resuelve el problema de la Asignación de las Unidades de Generación y Almacenamiento en un entorno estocástico (SUC), con 24 horas de anticipación. Se plantea el problema de optimización mostrado en la ecuación (4.1), cuyo objetivo principal es minimizar el coste total de operación para la producción de energía de la microrred bajo estudio. En esta función de coste se consideran dos componentes principales: el coste de la energía y el de la reserva rodante de las unidades controlables.

Por un lado, el coste de la energía considera el coste de combustible utilizado por las unidades controlables. Por otro lado, el coste de la reserva rodante está asociado a cuando la demanda de la microrred es superior o inferior a la disponibilidad de potencia generada, y se requiere el empleo de la reserva rodante de las unidades controlables para lograr el equilibrio generación-demanda. Los costes de reserva son típicamente mucho más bajos que los costes de arranque de una unidad generadora [126], [127]. La función objetivo esta sujeta a las restricciones (3.10)-(3.25).

La ecuación (3.10), representa el balance de potencia, que indica que la suma de las potencias generada por cada unidad generadora controlable o no, ($P_{i,t}$), (MT, DE, WT, PV), y la potencia generada o consumida por el BESS debe ser igual a

la potencia demandada predicha por la microrred en cada momento t (\hat{P}_t^d). Los límites de potencia máximo ($P_{max,i}$) y mínimo ($P_{min,i}$) de las unidades de generación controlables (DE y MT) se representan por las ecuaciones (3.12) y (3.13). Para las baterías, las ecuaciones (3.14) y (3.15), definen la potencia máxima de carga (P_{max}^c) y descarga (P_{max}^d) del BESS. El estado de carga del BESS (SOC_t) está definido por (3.17) y los límite máximo (SOC_{max}) y mínimo (SOC_{min}) del SOC se impone en (3.16).

La estimación de la reserva rodante a subir ($R_{i,t}^{up}$) de las unidades de generación controlables (MT y DE) está limitada por la diferencia entre la capacidad máxima de potencia de la unidad y la potencia que esta entrega, ecuaciones (3.18)-(3.20). Del mismo modo, la reserva rodante a bajar ($R_{i,t}^{down}$) se incluye en (3.22). La suma de la reserva rodante de los generadores mencionados anteriormente (MT y DE) y el aporte del banco de batería (BESS), constituyen la reserva total ascendente de la microrred (R_t^{up}), quedando expresada en la restricción que representa la ecuación (3.21). De igual manera se obtiene la reserva total descendente (R_t^{down}), que se expresa en (3.23).

Las ecuaciones (3.24) y (3.25) representan las restricciones de confiabilidad impuestas en el problema, que garantiza que la reserva rodante, tanto ascendente como descendente, cubra el error en la estimación de la demanda en un 99,73 %, que asegura la operación en isla de la microrred.

- En la tercera etapa, una vez resuelto el problema del SUC, ya se conocen que unidades generadoras van a estar encendidas o apagadas. Entonces se establece un estudio de caso en tiempo real. Es decir, sería una etapa durante la operación en la que el EMS de la microrred se da cuenta de que la demanda predicha no casa con la real.

Se define el parámetro ω_t como la diferencia entre demanda predicha y real en un instante t . Esta diferencia (error), provoca que sea necesario reajustar la reserva rodante de las unidades generadoras controlables (MT y DE) y del BESS. Entonces, se resuelve un segundo problema de optimización, Despacho Económico [128], en el que, una vez conocido los generadores que están encendidos (etapa anterior), se determina cuál o cuales de ellos van a hacer frente a esta variación en la demanda.

En este segundo problema de optimización (DE), se considera que la variable binaria $\delta_{i,t}$ permanece constante y la demanda real difiere de la prevista:

$$P_t^d = \hat{P}_t^d + \omega_t,$$

donde \hat{P}_t^d y P_t^d son, respectivamente, la potencia estimada y la real demandada por la microrred, y ω_t es la diferencia entre la potencia de demanda estimada y la potencia de demanda real para un escenario determinado (error). Esto significa que la reserva rodante que se determinó en la primera etapa (R_t^{up} y R_t^{down}) se ve afectada por las variaciones en la demanda, lo que provoca un ajuste de la reserva de las unidades controlables (Mt y DE) y el banco de baterías (BESS).

Por lo tanto, el problema en esta etapa es encontrar las variaciones de la potencia suministrada por los generadores controlables (MT y DE) y el BESS, ($\Delta P_{i,t}$). Para hacer esto, se formula un segundo problema de optimización que se expresa en la ecuación 4.2. La función objetivo planteada propone minimizar el coste total de operación de la microrred, para ello considera el coste de combustible utilizado por las unidades de generación controlables para dar respuesta a la variación de la demanda en tiempo real.

Este nuevo problema de optimización está sujeto a las restricciones (4.3)-(4.7). La ecuación 4.3 representa el balance de potencia en estas nuevas condiciones ($P_t^d = \hat{P}_t^d + \omega_t = \sum_{i=1}^5 (P_{i,t} + \Delta P_{i,t})$). Los límites de potencia máximo ($P_{max,i}$) y mínimo ($P_{min,i}$) de los generadores controlables (MT y DE) deben estar en una banda ($P_{i,t} + \Delta P_{i,t}$), y se representan por las ecuaciones (4.4) y (4.5). Para las baterías se redefinen las restricciones para dar respuesta a las variaciones de la demanda, el estado de carga del BESS (SOC_t), queda definido en la expresión (4.6) y la potencia máxima de carga (P_{max}^c) y descarga (P_{max}^d) en (4.7).

4.2.2.1 Asignación de las unidades de generación y almacenamiento en un entorno estocástico

A continuación, se presentan la función objetivo y las diferentes restricciones involucradas en el problema.

1. Función objetivo.

$$\min \sum_{t=1}^{24} [a_{DE} \delta_{DE,t} + b_{DE} P_{DE,t} + c_{DE} P_{DE,t}^2 + r_{DE}^{up} R_{DE}^{up} \\ a_{MT} \delta_{MT,t} + b_{MT} P_{MT,t} + c_{MT} P_{MT,t}^2 + r_{MT}^{up} R_{MT}^{up}], \quad (4.1)$$

donde a_i , b_i and c_i son los coeficientes de coste de combustible asociados a cada unidad despachable y R_i^{up} y r_i^{up} son, respectivamente, la reserva rodante de la unidad despachable i y su coste correspondiente. Vale la pena señalar que los costes asociados con las unidades controlables son los mismos que los considerados en [129], [57].

2. Restricciones

La función objetivo está sujeta a las siguientes restricciones, ecuaciones (3.10)-(3.25):

$$s.a. \quad \hat{P}_t^d = P_{MT,t} + P_{DE,t} + P_{WT,t} + P_{PV,t} + P_{BESS,t} \quad \forall t, \quad (3.10)$$

$$P_{min_{DE}} \delta_{DE,t} \leq P_{DE,t} \leq P_{max_{DE}} \delta_{DE,t}, \quad (3.12)$$

$$P_{min_{MT}} \delta_{MT,t} \leq P_{MT,t} \leq P_{max_{MT}} \delta_{MT,t}, \quad (3.13)$$

$$P_{BESS,t} \leq P_{BESS}^{max}, \quad (3.14)$$

$$P_{BESS,t} \geq P_{BESS}^{min}, \quad (3.15)$$

$$SOC^{min} \leq SOC_t \leq SOC^{max}, \quad \forall t, \quad (3.16)$$

$$SOC_{t+1} = SOC_t - \begin{cases} P_{BESS,t} \Delta t \eta_c & \text{si } P_{BESS,t} < 0 \\ \frac{P_{BESS,t} \Delta t}{\eta_d} & \text{si } P_{BESS,t} > 0 \end{cases}, \quad \forall t, \quad (3.17)$$

$$R_{i,t}^{up} = P_{max_i} - P_{i,t} \geq 0, \quad (3.18)$$

$$R_{DE,t} = P_{DE}^{max} - P_{DE,t}, \quad (3.19)$$

$$R_{MT,t} = P_{MT}^{max} - P_{MT,t}, \quad (3.20)$$

$$R_t^{up} = R_{DE,t}^{up} + R_{MT,t}^{up} + R_{BESS,t}^{up}, \quad \forall t, \quad (3.21)$$

$$R_{i,t}^{down} = P_{i,t} - P_{min_i} \geq 0, \quad (3.22)$$

$$R_t^{down} = R_{DE,t}^{down} + R_{MT,t}^{down} + R_{BESS,t}^{down} \quad \forall t, \quad (3.23)$$

$$R_t^{up} \geq 3 \sigma_t \quad \forall t, \quad (3.24)$$

$$R_t^{down} \geq 3 \sigma_t \quad \forall t, \quad (3.25)$$

δ_{it} binaria

P_{it} real

4.2.2.2 Despacho Económico

1. Función objetivo

La siguiente función objetivo minimiza el coste del combustible para la producción de energía de la microrred sujeto a las restricciones en (4.3)-(4.7). La función de coste se define como:

$$\begin{aligned} \min \sum_{t=1}^{24} & \left[a_{DE} \delta_{DE,t} + b_{DE} (P_{DE,t} + \Delta P_{DE,t}) + c_{DE} (P_{DE,t} + \Delta P_{DE,t})^2 \right. \\ & \left. + a_{MT} \delta_{MT,t} + b_{MT} (P_{MT,t} + \Delta P_{MT,t}) + c_{MT} (P_{MT,t} + \Delta P_{MT,t})^2 \right]. \end{aligned} \quad (4.2)$$

2 Restricciones

- Balance de Potencia:

La variación en la demanda debe ser satisfecha por los generadores,

$$\omega_t = \Delta P_{MT,t} + \Delta P_{DE,t} + \Delta P_{BESS,t} \quad \forall t, \quad (4.3)$$

- Límite de generación:

La potencia generada debe estar en una banda debido a limitaciones físicas:

$$P_{min_{DE}} \delta_{DE,t} \leq P_{DE,t} + \Delta P_{DE,t} \leq P_{max_{DE}} \delta_{DE,t} \quad \forall t, \quad (4.4)$$

$$P_{min_{MT}} \delta_{MT,t} \leq P_{MT,t} + \Delta P_{MT,t} \leq P_{max_{MT}} \delta_{MT,t} \quad \forall t, \quad (4.5)$$

- Restricciones del almacenamiento:

El estado de carga de la batería debe cumplir las restricciones impuestas en (3.15)-(3.17). Por lo tanto, esas restricciones pueden reformularse como:

$$SOC_t = \begin{cases} SOC_{t-1} - \frac{\tilde{P}_{BESS,t}}{\eta_d} & if \quad \tilde{P}_{BESS,t} \geq 0, \\ SOC_{t-1} - \Delta t \tilde{P}_{BESS,t} \eta_c & if \quad \tilde{P}_{BESS,t} \leq 0, \end{cases} \quad (4.6)$$

$$-P_{max}^c \delta_{BESS,t} \leq \tilde{P}_{BESS,t} \leq P_{max}^d \delta_{BESS,t}, \quad (4.7)$$

donde para simplificar la expresión anterior se define $\tilde{P}_{BESS,t} = P_{BESS,t} + \Delta P_{BESS,t}$.

4.2.3 Resultados de las simulaciones

En este apartado se presentan los resultados obtenidos de aplicar el algoritmo a la microrred considerada como caso de estudio, descrita en 3.4.1 y 3.4.2.1, para comprobar su validez. En esta Tesis, se planteó un objetivo adicional que consiste en evaluar como influyen los parámetros del BESS en el coste de operaciones de la microrred. Para ello, se proponen cinco escenarios el caso base (caso 1) corresponde a los valores nominales dados por el fabricante del BESS. Los cuatro escenarios restantes (caso 2 al caso 5) modifican los parámetros del BESS. La Tabla 4.1 muestra los valores de los parámetros del BESS que se usaron para encontrar la variante más económica.

Tabla 4.1 Escenarios de los parámetros del Sistema de Almacenamiento de Energía por Baterías (BESS), extraída de [1].

Case	P_{max}^c (kW)	P_{max}^d (kW)	SOC_{min} (kWh)	SOC_{max} (kWh)
1	120	120	70	280
2	80	80	70	280
3	120	120	70	250
4	120	120	0	280
5	120	120	0	250

4.2.3.1 Caso Base

La Tabla 4.2 muestra las unidades de generación controlables (MT y DE) que se seleccionan para generar en cada hora para cubrir la demanda estimada. Esta solución del problema satisface la condición necesaria para alcanzar una solución robusta del problema ($3\sigma_t$).

Tabla 4.2 Asignación de las unidades controlables. Caso base, extraída de [1].

Unit	Hours (1-24)																								
	MT	1	1	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1
DE	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0

La Figura 4.1 muestra el valor de la potencia suministrada por cada unidad generadora en cada instante de tiempo, 24 horas en adelante, como resultado del despacho económico (etapa tres).

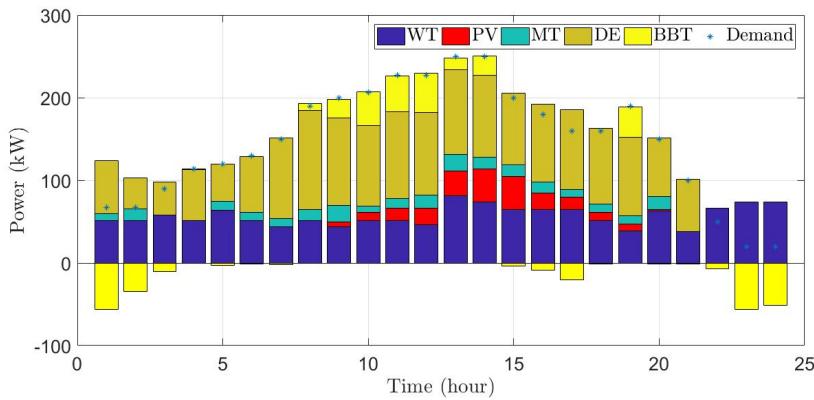


Figura 4.1 Cubrimiento de la curva de carga diaria. Caso base, extraída de [1].

En la Figura 4.1, se observa que hay generación de potencia eólica (WT) durante las 24 horas del día y potencia solar (PV) en el intervalo de tiempo de 9 horas a 19 horas, lo cual se corresponde con los perfiles de generación aportados en la Figura 3.5. En el caso del

banco de batería (BESS), los valores negativos de la potencia indican que se está cargando y los valores positivos indican la potencia suministrada por la batería para contribuir a la cobertura de la curva de demanda.

De acuerdo con la Figura 4.1 el BESS se carga durante las horas de baja demanda, de 1 a 3 horas, entre 15 y 17 horas y de 22 a 24 horas, cuando la demanda comienza a disminuir después de las horas pico, 13 y 14 horas, y 23 y 24 horas. El BESS se descarga desde las 8 horas que comienza a crecer el consumo hasta el pico de demanda que ocurre a las 14 horas, y posteriormente entrega potencia también de 19 a 20 horas.

La Figura 4.2 muestra el proceso de carga y descarga del BESS, indicando los valores de potencia y del estado de carga de la misma en cada hora. Consecuente con la Figura 4.1, la batería comienza a descargarse a partir de las 8 h hasta las 14 h, entregando una potencia entre 10 a 50 kW aproximadamente, y vuelve a descargarse significativamente de 19 a 20 horas, con una contribución aproximada de 40 kW. La variación del valor de la energía almacenada (SOC) en el BESS se corresponde con el proceso de carga y descarga.

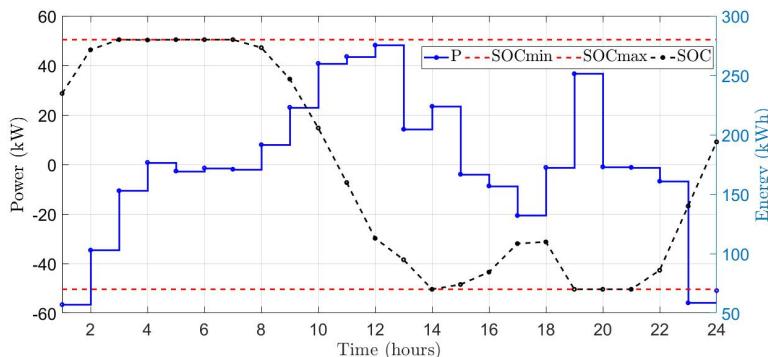


Figura 4.2 Proceso de carga y descarga de la batería. Caso base, extraída de [1].

La Tabla 4.3 muestra el error total (ω_t) entre la potencia real demandada del escenario en estudio y la potencia demandada estimada ($\Delta P_{i,t}$), que a su vez indica el ajuste de la reserva rodante de las unidades controlables (MT y DE) y el sistema de almacenamiento (BESS), calculada en la primera etapa (R_t^{up} y R_t^{down}), de acuerdo con la ecuación 4.3.

La Figura 4.3 representa las variables $\Delta P_{i,t}$, es decir, la diferencia entre la potencia entregada por los generadores como resultado del problema SUC y la potencia real entregada en el caso de estudio del Despacho Económico. Por lo tanto, si ω_t está por encima de la línea cero, significa que hay un exceso de potencia planeado.

Es fácil ver que las variaciones más grandes en la potencia generada por las unidades controlables tienen lugar en el generador diésel (DE), mientras que en la mircoturbina (MT), las variaciones son significativamente más bajas. Este hecho es el resultado de la funciones de costes (4.1) y (4.2) cuyos parámetros de costes se muestran en la Tabla 3.2.

Tabla 4.3 Valores de la diferencia en las potencias entregadas ($\Delta P_{i,t}$) y el error (ω_t), extraída de [1].

Hour	$\Delta P_{i,t}$ (kW)			ω_t (kW)
	MT	DE	BESS	
1	-0.818	-3.632	4.050	-0.399
2	-0.318	-2.382	3.524	0.824
3	0	-2.382	-1.687	-4.069
4	0	-2.382	-4.886	-7.268
5	-0.318	-2.382	-1.002	-3.702
6	0.037	0.275	0	0.311
7	0.126	0.946	-0.708	0.364
8	0.126	0.946	-0.229	0.844
9	0	0.946	-1.152	-0.207
10	0.126	0.946	-0.392	0.679
11	0.126	0.946	-2.501	-1.430
12	0.126	0.946	1.181	2.253
13	0	0.946	-3.863	-2.917
14	0.126	0.946	0.030	1.102
15	0.126	0.946	-2.264	-1.192
16	0.126	0.946	-0.667	0.405
17	0.126	0.946	1.702	2.774
18	0.126	0.946	3.054	4.126
19	0.126	0.946	-1.835	-0.763
20	0.126	0.946	3.747	4.819
21	0	0.946	3.021	3.967
22	0	0	1.933	1.933
23	0	0	0.030	0.030
24	0	0	-1.086	-1.086

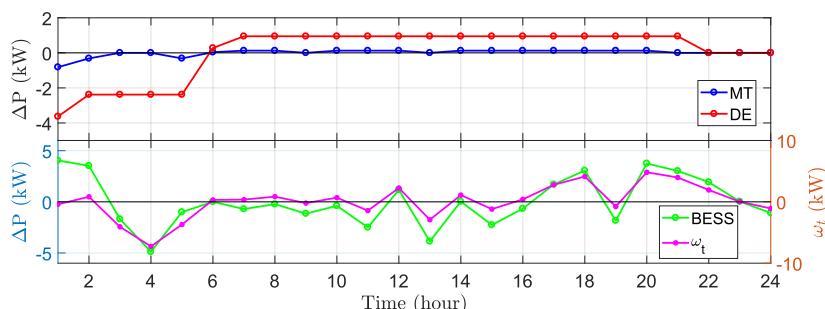


Figura 4.3 Estimación error (ω_t) y diferencia en las potencias entregadas ($\Delta P_{i,t}$), extraída de [1].

4.2.3.2 Influencia de los parámetros del BESS en el problema

La tabla 4.4 muestra los resultados de la aplicación del algoritmo a cada caso de estudio propuesto. En la columna seis (*Cost*), se puede apreciar el valor de la función de coste en \$ y en la columna siete una comparación en % del caso base con respecto a los otros casos de estudio. Como resultado de las simulaciones, se observa que el Caso 4 es el que proporciona el mayor ahorro en el coste del combustible, con un 8,55 %.

Tabla 4.4 Resultados por escenarios de los parámetros del Sistema de Almacenamiento de Energía por Baterías (BESS), extraída de [1].

Case	P_{max}^c (kW)	P_{max}^d (kW)	SOC_{min} (kWh)	SOC_{max} (kWh)	Cost (\$)	Savings (%)
1	120	120	70	280	3.154,62	0,00
2	80	80	70	280	3.159,38	-0,15
3	120	120	70	250	3.230,73	-2,41
4	120	120	0	280	2.884,77	8,55
5	120	120	0	250	2.950,52	6,48

En el caso 2, el valor de la potencia máxima de carga y descarga del sistema de almacenamiento de energía se reduce en un 33 %. El resultado obtenido aumenta el coste de operación en un 0.15 % que es despreciable. El caso 3 propone una reducción del SOC máximo en un 10.7 %, es decir, se reduce la capacidad de la batería. Como resultado, los costes de operación se incrementan en un 2.41 %. En el caso 5, se reduce el SOC mínimo de la batería, lo que permite utilizar unos 70 kWh adicionales con respecto al caso base, y la energía máxima que se puede almacenar (SOCmax) se reduce en un 10,7 %. Esta variante reducirá los costes en la instalación en un 6,48 %.

Para el Caso 4, la Tabla 4.5 muestra el resultado de la programación horaria de las unidades controlables. Se observa que la unidad generadora diésel entrega potencia durante 22 horas seguidas, 1 hora más que en el caso base. La unidad generadora microturbina suministra potencia durante 17 horas de forma irregular, 4 horas menos que en el caso base, y el BESS proporciona potencia durante 19 horas de forma irregular (Figura 4.4), 1 hora menos que en el caso base.

Tabla 4.5 Asignación de las unidades controlables. Caso 4, extraída de [1].

Unit	Hours (1-24)																							
	MT	0	1	0	1	0	1	1	0	1	1	1	1	0	0	1	1	1	1	0	1	1	1	1
DE	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0

Es de destacar que la potencia de descarga BESS alcanzada con esta alternativa (Figura 4.4) es mucho mayor en comparación con los valores obtenidos en el caso base (Figura 4.1), particularmente entre 9 a 14 h, que es el momento con el mayor consumo.

El análisis de las Figuras 4.4 y 4.5 muestra que los valores de descarga, es decir entrega de potencia, por parte del sistema de almacenamiento (BESS), crecen significativamente con respecto al caso base. En el intervalo de tiempo de 8 a 14 horas alcanza valores superiores a 50 kW, y particularmente entre las 9 y 10 horas aporta aproximadamente 100 kW, muy por encima de los valores que se alcanzan en el caso base. Este resultado se corresponde con valores de energía almacenada máximos de 250 kWh entre las 3 y las 7 horas. Teniendo en cuenta que la carga y descarga de la batería no se valora económica y que sin embargo provoca una disminución de la entrega de potencia por parte de las fuentes de energía controlables, que consumen combustible, explica que esta variante sea más económica.

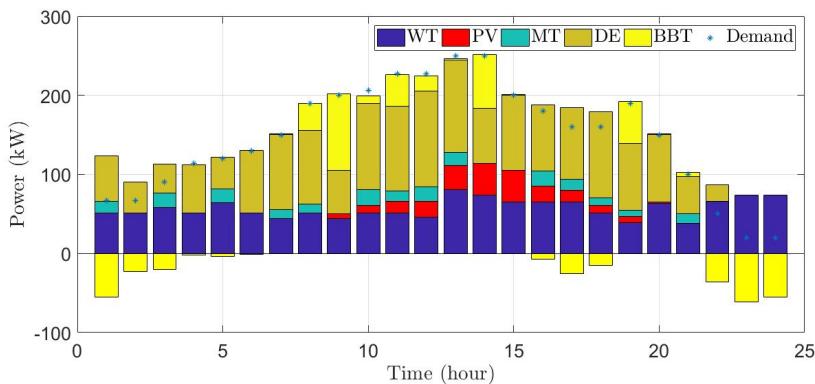


Figura 4.4 Cubrimiento de la curva de carga diaria. Caso 4, extraída de [1].

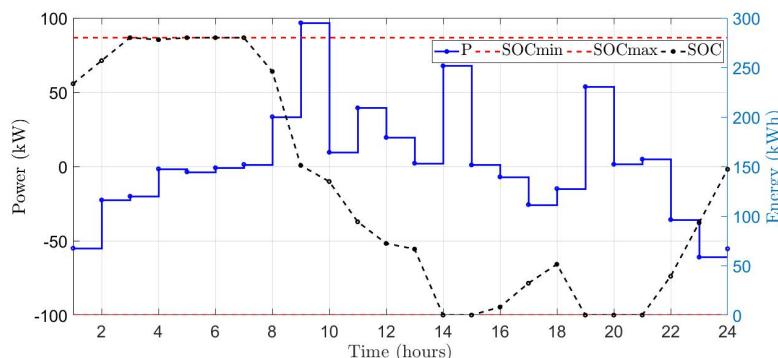


Figura 4.5 Proceso de carga y descarga de la batería. BESS Caso 4, extraída de [1].

4.2.4 Conclusiones

En esta Sección, se ha presentado el diseño de un EMS para una microrred y se propone un modelo de MINLP para la formulación del problema de optimización. El algoritmo se aplica a una microrred utilizada como caso de estudio y se comprueba su rendimiento. A la vista de los resultados obtenidos, cabe destacar las siguientes aportaciones:

1. Se propone un enfoque clásico basado en MILP para resolver el problema de la Programación Horaria de las Unidades de Generación y Almacenamiento, en un entorno estocástico, 24 horas en adelante, en una microrred que opera en modo aislada.
2. El algoritmo plantea un primer problema de optimización para determinar las unidades de generación que van a estar sincronizadas en la microrred. El algoritmo proporciona una solución que garantiza que la reserva rodante, tanto a subir como a bajar, aportada por las unidades de generación controlables (MT y DE) y el BESS cubre el error en la estimación de la demanda en un 99,73 %, lo que asegura la operación en isla de la microrred.
3. El algoritmo en el segundo problema de optimización asigna la potencia a las unidades de generación controlables (MT y DE) y al BESS que garantizan dar respuesta a las variaciones de la demanda en tiempo real, para ello, reajusta los valores de reserva rodante.
4. El algoritmo garantiza que el EMSs controle en cualquier instante de tiempo t que los desbalances de potencia que surgen por la diferencia entre la potencia real y la pronosticada en el intervalo de 24 h, se cubren con la generación procedente de la reserva rodante, tanto a subir como a bajar, aportadas por las fuentes de energía controlables (DE y MT) y el BESS. Con estos resultados asegura el funcionamiento en isla de la microrred en un 99,73 %.
5. Como cuestión interesante, se planteó evaluar la influencia de los parámetros del BESS en la solución del problema de optimización. El algoritmo, cuando el BESS dispone de mayor capacidad de energía para entregar a la microrred, logra disminuir en un 8 % el coste total de operación de la microrred.

4.3 Enfoque Computacional Evolutivo

4.3.1 Introducción

Esta sección plantea un segundo algoritmo que propone un enfoque computacional evolutivo para abordar el problema de optimización asociado a la PGUGyA de una microrred, presentado en la Sección 4.2. A diferencia del algoritmo anterior, en este se plantean múltiples modos de operación de la microrred, y se define una función objetivo diferente para cada uno. Dos de ellos se ocupan de optimizar factores económicos y ambientales, mientras que el tercero se plantea garantizar el funcionamiento confiable en isla de la microrred.

Los problemas de optimización se modelan como MILNP. Las funciones objetivos incorporan la función de coste de combustible de las unidades de generación controlables (MT y DE), cuyos costes son cuadráticos con la potencia, y la función de coste de arranque y parada de estas propias unidades (MT y DE), que se modelan con una función exponencial. Ambas funciones de costes le dan un carácter no lineal al problema. Las restricciones que se introducen son lineales y todas las variables son reales.

Para evaluar la efectividad del algoritmo propuesto, se utiliza un caso de prueba que consiste en la microrred cuya estructura y datos se informaron en las secciones 3.4.1 y 3.4.2.1.

4.3.2 Formulación del problema.

El EMS propone una estrategia de optimización que plantea tres modos de operación de la microrred, y define un problema de optimización diferente para cada uno, que presentan conflictos entre sí. El primer modo de operación propone una función objetivo para minimizar el coste total de operación de la microrred. El segundo modo de operación plantea reducir el impacto ambiental de estos sistemas de energía eléctricos, para ello propone una función objetivo para minimizar el coste de las emisiones de gases de efecto invernadero. Finalmente, el tercer modo de operación propone una función objetivo para minimizar el coste total de operación en un entorno estocástico, al considerar la predicción de la demanda. Incorpora al problema una restricción que garantiza el suministro de potencia para diferentes niveles de confiabilidad, para asegurar el funcionamiento en isla de la microrred.

Por tanto, las variables de decisión incluyen la potencia de salida de las unidades de generación controlables ($P_{i,t}$), el estado de carga/descarga de energía del BESS (SOC_i), y en el caso del tercer objetivo se adiciona la reserva rodante a subir ($R_{i,t}^{up}$) y a bajar ($R_{i,t}^{down}$) proporcionada por las unidades de generación controlables (MT y DE) y el BESS.

4.3.2.1 Modos de operación de la microrred

Como se ha introducido en la Sección 3.3, existe una gran cantidad de limitaciones y parámetros de coste a tener en cuenta para programar la generación de energía en una microrred. En esta sección se presentan los tres modos de operación considerados en este trabajo. En cada uno de ellos, se sigue un cierto criterio de operación para optimizar una función de coste particular.

1. Modo de Operación Económico.

Para este modo de operación se plantea el problema de optimización mostrado en la ecuación (4.8), cuyo objetivo principal es minimizar el coste total de operación para la producción de energía de la microrred. La función de coste considera los siguientes componentes:

- Costes de operación y mantenimiento de las unidades controlables (DE y MT),
- Costes de arranque de las unidades controlables (DE y MT).
- Coste del combustible y del gas de las unidades generadoras controlables (DE y MT) respectivamente.

La función de coste se define matemáticamente de la siguiente manera:

$$CF_{ec} = C_{OM_{DE}} + C_{OM_{MT}} + C_{SU_{DE}} + C_{SU_{MT}} + \sum_{\forall t} (C_{DE,t} + C_{MT,t}) . \quad (4.8)$$

donde:

$C_{OM_{DE}}$: Coste de operación y mantenimiento del Generador Diesel, ecuación (3.26).

$C_{OM_{MT}}$: Coste de operación y mantenimiento de la Microturbina, ecuación (3.27).

$C_{SU_{DE}}$: Coste de arranque del Generador Diesel, ecuación (3.28).

$C_{SU_{MT}}$: Coste de arranque de la Microturbina, ecuación (3.29).

$C_{DE,t}$: Coste combustible Generador Diesel, ecuación (3.6).

$C_{MT,t}$: Coste combustible Microturbina, ecuación (3.8).

La función objetivo esta sujeta a las restricciones (3.11)-(3.17). La ecuación (3.11), representa el balance de potencia, que indica que la suma de las potencias generada por cada unidad generadora controlable o no, ($P_{i,t}$), (MT, DE, WT, PV), y la potencia generada o consumida por el BESS debe ser igual a la potencia demandada por la microrred en cada momento t (P_t^d). Los límites de potencia máximo (P_{max_i}) y mínimo (P_{min_i}) de las unidades de generación controlables (DE y MT) se representan por las ecuaciones (3.12) y (3.13). Para las baterías, las ecuaciones (3.14) y (3.15), definen la potencia máxima de carga (P_{max}^c) y descarga (P_{max}^d) del BESS. El estado de carga del BESS (SOC_t) está definido por (3.17) y los límite máximo (SOC_{max}) y mínimo (SOC_{min}) del SOC se impone en (3.16).

2. Modo de Operación Ecológico.

En este modo de operación, se plantea disminuir el impacto ambiental de la microrred. Se formula un problema de optimización con el objetivo principal de minimizar las emisiones de gases de efecto invernadero, provocadas por la presencia de fuentes de generación convencionales (MT y DE), a la vez que se garantiza el suministro eléctrico en la microrred.

Por lo tanto, según los modelos definidos en la Sección 3.3, la función de coste se puede escribir como en 4.9 y considera los siguientes componentes:

$$CF_{ef} = CEM_{DE} + CEM_{MT}. \quad (4.9)$$

donde:

CEM_{DE} : Coste de emisiones Generador Diesel, ecuación (3.30)

CEM_{MT} : Coste de emisiones Microturbina, ecuación (3.31)

La función objetivo esta sujeta a las mismas restricciones (3.11)-(3.17) que el problema de optimización planteado anteriormente, ecuación (4.8).

3. Modo de Operación Robusto

Como se mostró en la sección de modelado del sistema, en el apartado 3.3.1, este trabajo considera las incertidumbres en el pronóstico de la demanda. Además, se considera que la estimación del error en el pronóstico de la demanda sigue una distribución normal en el instante t , ($e_{DM,t} \sim \mathcal{N}(\mu_t, \sigma_t)$), con media (μ_t) igual a cero y desviación estándar (σ_t).

En este algoritmo, a diferencia del algoritmo anterior, se proponen distintos niveles de confiabilidad (n_r), atendiendo a los intervalos de semiancho de la desviación típica (σ_t) respecto a la media (μ_t), Figura 3.2. Este razonamiento permite proponer tres niveles de confiabilidad en el problema de optimización, valores de $n_r = 1$, $n_r = 2$ y $n_r = 3$. Por tanto, se puede afirmar que la potencia demandada en la microrred en un instante t se encuentra en el intervalo definido por $[\hat{P}_t^d + \mu_t - n_r \sigma_t, \hat{P}_t^d + \mu_t + n_r \sigma_t]$. Entonces, para garantizar el funcionamiento en isla de la microrred, se incorpora una restricción de confiabilidad al problema de optimización.

Este modo de operación es complementario a los descritos anteriormente, mantiene las expresiones de la función de coste (4.8)-(4.9) al igual que las restricciones (3.11)-(3.17) e incorpora las restricciones (3.18)-(3.23).

La estimación de la reserva rodante a subir ($R_{i,t}^{up}$) de las unidades de generación controlables (MT y DE) se expresan matemáticamente en las ecuaciones (3.19)-(3.20). Del mismo modo, la reserva rodante a bajar ($R_{i,t}^{down}$) se incluye en (3.22). La suma de la reserva rodante de los generadores mencionados anteriormente (MT y DE) y el aporte del BESS, constituyen la reserva total a subir de la microrred (R_t^{up}), quedando expresada en la restricción que representa la ecuación (3.21). De igual manera se obtiene la reserva total a bajar (R_t^{down}), que se expresa en (3.23).

La ecuación (4.10) representa la restricción de confiabilidad impuesta en el problema que garantiza que la reserva rodante, tanto a subir como a bajar, cubra el error en la estimación de la demanda según el valor de (n_r)

$$R_{DE,t} + R_{MT,t} \geq n_r \sigma_t, \quad (4.10)$$

donde:

σ_t : desviación estándar del error estimado

n_r : parámetro escalar que fija el grado de confiabilidad de la solución.

4.3.3 Enfoque computacional evolutivo

En este apartado se propone un enfoque computacional evolutivo para abordar el problema de optimización presentado en la Sección 4.3.2. Para este fin, en esta sección se desarrolla un Algoritmo Genético (GA).

4.3.3.1 Algoritmo Genético

Los Algoritmos Genéticos (GAs) son algoritmos metaheurísticos usados ampliamente para resolver problemas complejos de ingeniería [130, 131]. Se basan en la teoría de la evolución biológica de Darwin. La idea principal de los GAs radica en imitar el proceso de selección natural, donde se seleccionan los individuos más aptos para la reproducción con el fin de producir descendencia para la próxima generación.

En general, cada GA está compuesta por cuatro elementos principales [132]:

- Representación individual.
- Esquema de generación individual.
- Operadores genéticos.
- Función de adaptación (*fitness*).

La implementación del GA determina la programación horaria de los recursos energéticos de una microrred, en un periodo de 24 horas hacia delante. En la Sección 4.3.2 se presentó la formulación de la estrategia de optimización.

La idea básica es crear posibles soluciones (individuos), cada uno de los cuales representa una variable de optimización. Estos individuos, que inicialmente se crean de forma aleatoria mediante un esquema de generación individual, se agrupan en una lista denominada población. Esta población, evoluciona a través de diferentes generaciones mediante la aplicación de los siguientes operadores genéticos: selección, cruce y mutación [133].

4.3.3.2 Estructura del algoritmo genético propuesto

Las potenciales soluciones al problema de optimización tienen estructura cromosómica compuesta por las variables de diseño. Esta estructura se denomina individuo y cada variable de diseño es un gen. En este trabajo las variables de diseño son la potencia suministrada por las unidades de generación controlables (MT y DE), ($P_{i,t}$) y el estado de carga/descarga del BEES (SOC_t), ya que son los elementos de la microrred que tienen mayor influencia en el coste de la operación de la microrred.

En este trabajo se considera que las RESs, tales como PV y WT, siempre contribuyen a la potencia demandada, pues se ha considerado la mejor predicción posible, y los costes de operación y mantenimiento de estas unidades se consideran despreciables con respecto a los generadores controlables (DE y MT). Además como el balance de potencia para cada instante de tiempo debe cumplirse, el BESS suministra o consume potencia para cada instante t , lo que está determinado por el balance de potencia entre la demanda y la generación del resto de los elementos de la microrred.

1. Representación de la solución o individuos

En este trabajo, cada individuo se representa mediante una lista que contiene la potencia suministrada por las unidades controlables MT y DE ($P_{i,t}$) durante un período de 24 h a intervalos de 1 h. De ahí que el tamaño de la lista es de 48 elementos. Se debe destacar que la potencia suministrada o consumida por el BESS se puede obtener del balance de potencia. La Figura 4.6 muestra la representación de los individuos del GA.



Figura 4.6 Representación de la solución o individuos.

2. Operadores genéticos

- Para seleccionar los candidatos más aptos de la generación inicial en el GA, se ha utilizado el mecanismo de selección mediante torneo (*tournament selection mechanism*), ya que proporciona resultados adecuados [134].

Este método consiste en que cada torneo selecciona aleatoriamente un número de individuos, que compiten entre sí para ser elegidos como padres; el mejor se selecciona como uno de los padres para ser utilizado en operaciones de cruce y mutación [134]. Se ha demostrado que un tamaño de torneo de tres es adecuado para la mayoría de los problemas.

- Respecto a la operación de cruce se han evaluado dos esquemas: el operador de cruce de dos puntos (*Two-points*) y el operador de cruce mediante simulación binaria (*Binary Simulated*, SBX) [135].
 - El operador de cruce de dos puntos consiste en intercambiar la información genética de dos progenitores utilizando dos puntos como indicadores de los intercambios genéticos.
 - El operador de cruce mediante simulación binaria (SBX) simula un punto de cruzamiento para las variables continuas. Se basa en una función de distribución, que usa el parámetro η , llamado índice de distribución, para determinar la apertura de la distribución, y por tanto su capacidad de búsqueda.

Se usa para determinar la similitud entre los progenitores e hijos seleccionados. Un alto valor de η producirá semejanzas o parecidos entre los progenitores y los hijos, mientras que un pequeño valor de η producirá soluciones mucho más diferentes.

- El esquema de mutación utilizado es un algoritmo de mutación gaussiana a medida, donde cada variable puede cambiar de acuerdo con una distribución normal, centrada (media, μ) en el valor del gen mutado y desviación estándar σ . La variabilidad de un gen dado después de la mutación depende del valor de σ .

3. Función de adaptación (coste)

La función de coste que se usa depende del modo de operación de la microrred. Se han definido en la sección 4.3.2.1 tres modos de operación de la microrred que usan una sola función de coste: modo de operación económico, modo ecológico y modo de operación robusto.

En el modo de operación económico, la función objetivo objetivo se define:

$$\left\{ \begin{array}{ll} \text{si la solución es valida} & F = \text{ecuación (4.8),} \\ \text{sino} & F = \infty, \quad \text{sujeto a} \end{array} \right. \quad \begin{array}{l} (3.11), (3.12), (3.13), (3.14), \\ (3.15), (3.16), (3.17). \end{array} \quad (4.11)$$

En el caso del modo de operación ecológico, la función objetivo utilizada es:

$$\left\{ \begin{array}{ll} \text{si la solución es valida} & F = \text{ecuación (4.9),} \\ \text{sino} & F = \infty, \quad \text{sujeto a} \end{array} \right. \quad \begin{array}{l} (3.11), (3.12), (3.13), (3.14), \\ (3.15), (3.16), (3.17). \end{array} \quad (4.12)$$

En el caso del modo de operación robusto, la función de objetivo utilizada es:

$$\left\{ \begin{array}{ll} \text{si la solución valida} & F = \text{ecuación(4.8),} \\ \text{sino} & F = \infty, \quad \text{sujeto a} \end{array} \right. \quad \begin{array}{l} (3.11), (3.12), (3.13), (3.14), \\ (3.15), (3.16), (3.17), \\ (3.19), (3.20), (4.10). \end{array} \quad (4.13)$$

Es importante destacar que las soluciones no validas deben descartarse para que no participen en las generaciones futuras del GA. Para ello, las ecuaciones (4.11), (4.12), y (4.13) utilizan la pena de muerte para penalizar las soluciones no válidas. La pena de muerte imposibilita una solución para participar en las operaciones genéticas, ya que nunca serán seleccionadas.

4.3.3.3 Implementación del algoritmo genético

Hay muchas implementaciones posibles de GA de objetivo único [134]. En el enfoque propuesto, se ha utilizado un esquema *mu-plus-lambda* [136]. Esta variante consiste en crear las nuevas generaciones de tamaño λ entre la descendencia de tamaño μ y la población original (P_g). La selección se hace entre *mu-plus-lambda* individuos. El Algoritmo 1 muestra el enfoque implementado o pseudocódigo.

- El algoritmo comienza con una población inicial aleatoria P_i , la cual se evalúa. Es importante destacar que los individuos que forman la población inicial deben ser válidos. Este aspecto es relevante en problemas con múltiples restricciones como el que se describe en este trabajo (Sección 4.3.2).
- La descendencia μ se crea utilizando los operadores genéticos cruce y mutación p_{cx} y p_{mut} que se refieren a las probabilidades del cruce y la mutación, respectivamente. Estos parámetros del algoritmo se deben seleccionar cuidadosamente para garantizar una buena convergencia del GA.
- Una vez que la descendencia se crea, esta se evalúa y se selecciona una nueva población λ , a partir de la descendencia generada μ y la población previa P_g .

Este enfoque garantiza un buen nivel de elitismo ya que los progenitores y la descendencia compiten unos con otros para ser seleccionados para la próxima generación [136]. Una vez completado, el algoritmo selecciona los mejores individuos obtenidos a través de las generaciones

```

1 Crear población inicial  $P_i$ ;
2 Evaluar  $P_i$ ;
3  $P_g = P_i$ ;
4 while  $stop == False$  do
5   Selección de padres;
6   Creación descendencia  $\mu$  (cruce  $p_{cx}$  y mutación  $p_{mut}$ );
7   Evaluación  $\mu$  ;
8   Selección nueva población  $\lambda$  ( $\mu + P_g$ );
9    $P_g = \lambda$ ;
10 end
```

Algorithm 1: Esquema GA *mu-plus-lambda*

Un vez que finaliza el algoritmo, la población resultante contiene las mejores soluciones para el problema de optimización. Normalmente, el criterio de detención del algoritmo es un número dado de generaciones.

4.3.4 Resultados de las simulaciones

En esta sección se discute la aplicación del método evolutivo propuesto. El GA desarrollado se aplica a tres casos de estudios diferentes de la microrred que se muestra en la sección 3.4, Figura 3.4. Los escenarios propuestos tienen como objetivo resolver la programación horaria de los generadores, en el corto periodo de 24 horas, para ello se consideran conocidos la potencia demandada y la generación de los recursos renovables de la microrred, Figura 3.8.

El problema se ha resuelto considerando un dato por hora. Es importante resaltar que este tiempo puede reducirse, lo que implica el incremento del número de variables del problema, pero preservando la formulación del problema realizada en este trabajo.

Finalmente, se muestran los resultados con los valores de la función objetivo para diferentes modos de operación. El marco de simulación se desarrolló en Python utilizando la librería DEAP [137]. El simulador está disponible en [138].

4.3.4.1 Configuración del algoritmo genético

El diseño de la programación de la generación de la microrred se aborda mediante un GA, utilizando las reglas de selección, cruce y mutación propuestas en la Sección 4.3.3. La Tabla 4.6 contiene los principales parámetros de configuración de la implementación de GA.

El GA propuesto se ha probado bajo diferentes parámetros de configuración en términos de probabilidades de cruce y mutación. Los operadores genéticos de cruce se aplican de manera aleatoria a padres con una probabilidad superior a 0.5, comprendida entre 0.6 y 1.0 y el operador genético de mutación se aplica a cada descendiente (hijo), tras aplicar el operador de cruce, con una probabilidad inferior a 0.5, comprendida entre 0.2 y 0.4.

Además, para el método de cruce binario simulado (SBX) se realizó una evaluación detallada de la influencia del parámetro η , para ello, se proponen diferentes valores con el objetivo de determinar la probabilidad de crear soluciones (descendientes) alejada o similares a los padres, y su influencia en el resultado de la función de adaptación (coste).

Tabla 4.6 Parámetros del Algoritmo Genético (GA), extraída de [2].

Parameter	Value
λ	3000
μ	3000
Individuos	3000
Generaciones	1000
Selección	tamaño del torneo = 3
Cuce	Esquema de <i>Two-points</i> y <i>Binary Simulated</i> $p_{cx} = [0.6, 0.7, 0.8]$.
Mutación	Gaussian $p_m = [0.4, 0.3, 0.2]$, $\sigma = 30$.
Numero de simulaciones	30.

La figura 4.7 describe la evolución de los individuos a través del número de generaciones consideradas. Se muestra que 1000 generaciones fueron suficientes para garantizar la convergencia. Observar que la convergencia de los algoritmos se vería afectada por los valores usados de σ (desviación estándar del algoritmo de mutación gaussiana) que se usa en el proceso de mutación. Similar grado de convergencia se obtuvo para el resto de casos de estudios con el mismo valor de σ .

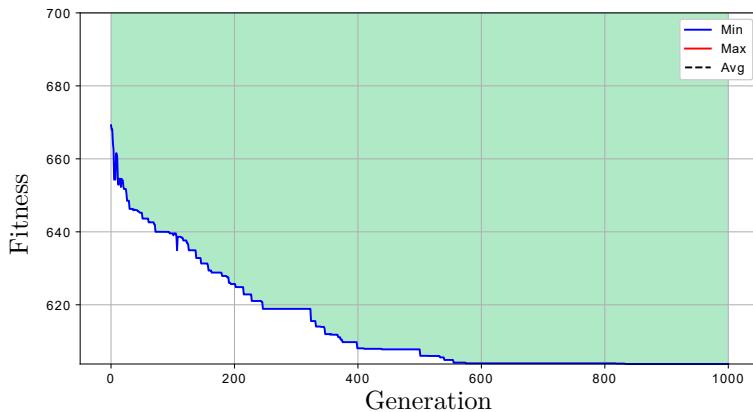


Figura 4.7 Evolución del Algoritmo Genético (GA) propuesto, caso de estudio 1, cruce de dos puntos, $p_c = 0.6$ y $p_m = 0.4$, extraída de [2].

4.3.4.2 Resultados de los casos de estudio

Para este problema, se proponen tres escenarios diferentes. A continuación se presentan los resultados para cada uno de ellos.

1. Caso de estudio 1. Modo de coste de operación económico.

Este caso de estudio considera el problema de optimización formulado en la ecuación (4.8). La función objetivo propone minimizar el coste total de operación de la microrred. Las mejores soluciones obtenidas usando el GA para este caso de estudio se enumeran en la Tabla 4.7. Además, la mejor solución de la programación horaria de los recursos energéticos de la microrred se muestra en la Figura 4.8.

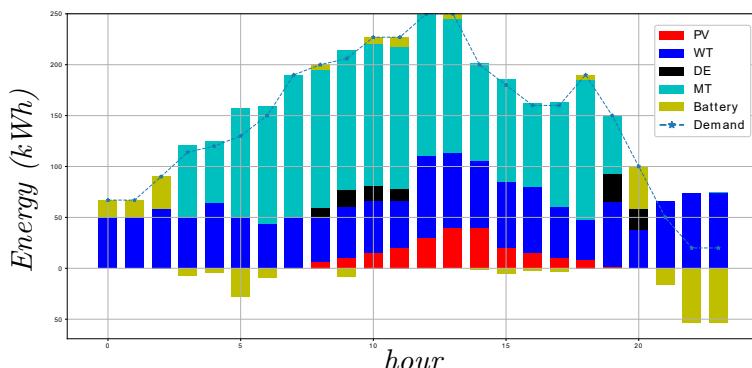
Se observa en la Tabla 4.7, que en el enfoque propuesto, utilizando los esquemas de cruces *Two-points* y *Binary Simulated*, (SBX), y el esquema de mutación gaussiano, conducen a soluciones muy similares. Se alcanza la mejor solución con el esquema de cruce SBX con $P_{cx} = 0.6$ y $P_{mut} = 0.4$. El valor de $eta = 0.01$, informa que existe una mayor probabilidad de que la solución encontrada es mejor cuando se distancia de sus padres. Este resultado, viene a decir que el operador SBX tiende a utilizar mayor exploración del espacio de búsqueda y por tanto, mayor diversidad para generar nuevas soluciones prometedoras.

Tabla 4.7 Resultados del caso estudio 1, expresado en €, extraída de [2].

Método	P_{cx}	P_{mut}	eta	$best(CF_{ec})$	$mean(CF_{ec})$	$\sigma(CF_{ec})$
SBX	0.6	0.4	0.01	592.637	602.995	5.725
	0.7	0.3		595.718	603.793	3.769
	0.8	0.2		594.888	606.089	5.930
	0.6	0.4	0.1	593.630	603.370	4.884
	0.7	0.3		594.013	604.439	4.065
	0.8	0.2		592.637	606.066	6.863
	0.6	0.4	1	594.390	604.762	6.793
	0.7	0.3		596.204	604.467	4.449
	0.8	0.2		596.737	608.589	6.823
	0.6	0.4	10	596.543	605.210	6.040
	0.7	0.3		594.180	604.773	6.059
	0.8	0.2		597.118	609.207	6.217
Two-points	0.6	0.4	-	595.173	603.146	4.513
	0.7	0.3		597.070	604.071	4.553
	0.8	0.2		595.863	605.758	6.237

La Figura 4.8, muestra la mejor solución de programación horaria de los recursos energéticos de la microrred cada hora. Se puede ver que la MT está conectada a la microrred 17 horas, generando valores altos de potencia, superiores a 55 kW, a diferencia de la unidad DE que se sincroniza 6 horas y entrega valores de potencia inferiores a 20 kW.

Este resultado se corresponde con las características de los costes de operación de los generadores MT y DE, mostrados en la Figura 3.6. Por tanto, en esta variante se obtiene el menor coste de operación de la microrred. Por otro lado, se puede afirmar que es la que menos impacto ambiental provoca, pues los costes de los gases de efecto invernadero provocado por la MT son menores que la unidad DE, Tabla 3.4

**Figura 4.8** Solución del caso de estudio 1. Programación Horaria de las Unidades Generadoras, extraída de [2].

Finalmente, la Figura 4.9 muestra la evolución del SOC y la potencia entregada o consumida por el BESS. Las barras representan los valores del SOC y la línea roja la potencia entregada o requerida por el banco de batería.

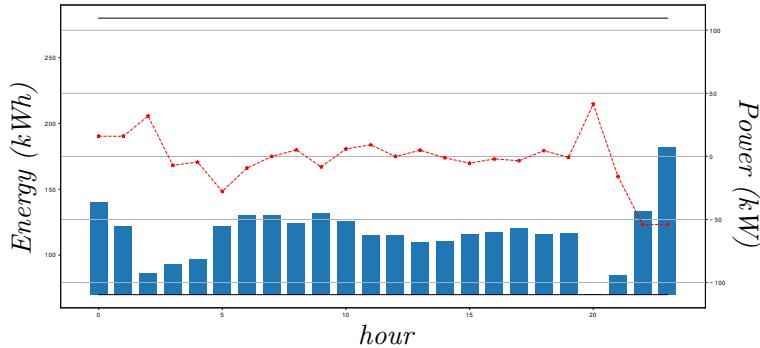


Figura 4.9 Gestión de la batería. Caso de estudio 1, extraída de [2].

2. Resultados del caso de estudio 2. Modo de operación ecológico.

El caso de estudio 2 considera el problema de optimización planteado en la ecuación (4.9). La función objetivo propone minimizar el coste de las emisiones de gases de efecto invernadero en la microrred. La Tabla 4.8 muestra las mejores soluciones alcanzadas entre diferentes esquemas de cruce y mutación usados para la aplicación del AG. La mejor solución se muestra en la Figura 4.10.

Tabla 4.8 Resultados del caso de estudio 2, expresado en ϵ , extraída de [2].

Método	P_{cx}	P_{mut}	eta	$best(CF_{ec})$	$mean(CF_{ec})$	$\sigma(CF_{ec})$
SBX	0.6	0.4	0.01	15577.973	17586.300	775.725
	0.7	0.3		15511.697	17597.337	954.216
	0.8	0.2		17043.111	18034.655	771.705
	0.6	0.4	0.1	15525.373	17386.520	714.173
	0.7	0.3		16279.030	17593.823	635.349
	0.8	0.2		15497.908	17983.249	635.349
	0.6	0.4	1	16359.787	17517.452	805.524
	0.7	0.3		16395.022	17948.340	694.802
	0.8	0.2		17095.309	17925.474	524.494
	0.6	0.4	10	15580.220	17535.896	765.017
	0.7	0.3		16470.354	17857.965	662.151
	0.8	0.2		17324.083	18946.675	892.987
Two-points	0.6	0.4	-	16107.14	19070.07	884.53
	0.7	0.3		17904.88	19878.66	889.12
	0.8	0.2		18972.78	20204.18	765.06

Según la Tabla 4.8 se alcanza la mejor solución utilizando el método de cruce SBX, para valores $P_{cx} = 0.7$ y $P_{mut} = 0.3$. Esta mejor solución se logra cuando existe mayor probabilidad de crear soluciones hijas (descendencia) alejadas de los padres, inducido por el valor de $eta = 0.01$. Por tanto, el operador de cruce SBX aumenta su capacidad de exploración y promueve mayor diversidad para generar nuevas soluciones.

La Figura 4.10 muestra la mejor solución de programación horaria de los recursos energéticos de la microrred cada hora. Se puede ver que la MT está conectada a la microrred 15 horas, generando valores altos de potencia, superiores a 55 kW, a diferencia de la unidad DE que se sincroniza 15 horas y entrega valores de potencia inferiores a 15 kW.

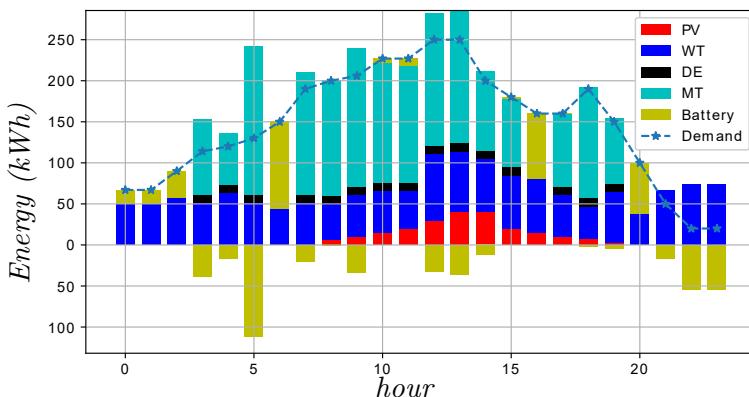


Figura 4.10 Solución del caso de estudio 2. Programación Horaria de las Unidades Generadoras, extraída de [2].

Así, analizando la Figura 4.10 se puede ver que, aunque la unidad DE está más tiempo conectada a la red en este caso de estudio, 9 horas más que el caso de estudio 1, la potencia generada por dicha unidad es menor comparada con el caso de estudio 1, y aportando valores de potencia inferiores a 15 kW, lo que provoca que sus costes de operación sea muy superiores a los costes de la MT. Esto es una consecuencia de que el coste de las emisiones de los gases de efecto invernadero producidas por DE son muy superiores a los costes producidos por la MT, como se expuso en la Tabla 3.4.

Adicionalmente la contribución del BESS ocasionó la desconexión de las unidades de generación controlables en la hora 6, por tanto, este resultado contribuye a la reducción de las emisiones de gases de efecto invernadero de la microrred.

La Figura 4.11 describe la evolución del SOC y la potencia suministrada o demandada por el BESS (las barras representan el SOC, la línea roja la potencia suministrada o absorbida por el BESS en cada instante). Se puede notar que en este modo de operación, el BESS se utilizó para reducir la potencia generada por las unidades controlables, contrario a lo alcanzado con el modo de operación económico, que minimizó el coste total de operación de las unidades de generación.

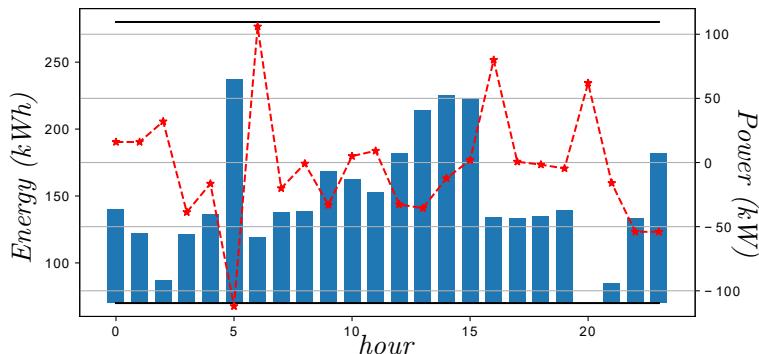


Figura 4.11 Gestión de la batería. Caso de estudio 2, extraída de [2].

3. Resultados del caso de estudio 3. Modo de operación robusto.

El caso de estudio 3 considera el problema de optimización planteado en la ecuación (4.8). La función objetivo propone minimizar el coste total de operación de la microrred, en un entorno estocástico, igual que en el caso de estudio 1.

La diferencia radica que en este caso, se propone garantizar el suministro de potencia para diferentes niveles de confiabilidad, definidos en la Sección 4.3.2.1, que aseguren el funcionamiento en isla de la microrred. Por tal motivo se incorpora una restricción adicional al problema de optimización. La Tabla 4.9 muestra los resultados de este caso de estudio.

Tabla 4.9 Resultados del caso estudio 3, expresado en €, extraída de [2].

Método	P_{cx}	P_{mut}	eta	$best(CF_{ec})$	$mean(CF_{ec})$	$\sigma(CF_{ec})$
SBX	0.6	0.4	0.01	610.804	619.718	4.017
	0.7	0.3		613.942	622.898	4.198
	0.8	0.2		615.287	623.017	5.130
	0.6	0.4	0.1	612.770	621.496	4.921
	0.7	0.3		611.888	623.111	4.604
	0.8	0.2		612.615	623.970	5.563
	0.6	0.4	1	613.722	621.852	4.399
	0.7	0.3		613.636	625.127	5.210
	0.8	0.2		615.364	625.648	5.573
	0.6	0.4	10	613.483	621.520	5.122
	0.7	0.3		614.783	624.422	5.773
	0.8	0.2		617.842	627.119	6.373
Two-points	0.6	0.4	-	613.579	622.957	4.301
	0.7	0.3		614.154	626.400	5.578
	0.8	0.2		610.792	625.598	6.468

La Tabla 4.9 muestra las mejores soluciones alcanzadas entre diferentes esquemas de cruce y mutación usados para la aplicación del AG. Es necesario hacer los siguientes comentarios:

- En contraste con el caso de estudio 1 (Tabla 4.7), el valor de ajuste de la función de costes (fitness) alcanzó valores más altos.
- Este hecho es una consecuencia del cubrimiento del error en la estimación de la demanda con la reserva rodante aportada por las unidades de generación controlables (MT y DE) y el BESS. Proporcionar reserva rodante tiene un coste asociado al incremento de consumo de combustible de las unidades DE y MT.
- En este modo de operación el nivel de confiabilidad $n_r = 3$ se garantiza. Es decir, la operación aislada de la microrred se garantiza en un 99,7 %.
- Se alcanza la mejor solución utilizando el método de cruce *Two-points* para el caso en el que los valores de probabilidad de cruzamiento y mutación, respectivamente, es de 0.8 y 0.2.
- Esta mejor solución en el caso de estudio 3 representa un incremento del 3.06 %, en el coste total de operación de la microrred, con respecto a la mejor solución del caso de estudio 1.
- Otra consideración interesante es la siguiente:

La solución óptima en el caso de estudio 2 (modo de operación ecológico), se obtuvo utilizando el método SBX, para valores $P_{cx} = 0.7$, $P_{mut} = 0.3$ y $eta = 0.01$. Si se observa en la Tabla 4.9 esta configuración logra que el coste de operación de la microrred ascienda a 613.942 €, muy próximo a la mejor solución obtenida 610.792 €.

La Figura 4.12 muestra la mejor solución de programación horaria de los recursos energéticos de la microrred cada hora. Se hacen las siguientes consideraciones:

- Se puede ver que la MT está conectada a la microrred 17 horas, generando valores altos de potencia, superiores a 55 kW, muy similar al caso de estudio 1. La unidad DE se sincroniza 4 horas, 2 horas menos que en el caso 1, y entrega valores de potencia inferiores a 15 kW, excepto en las horas 11 y 21 que entrega una potencia superior.
- Este resultado favorece a la disminución de costes, pues los costes de operación de la MT para los valores de potencia que entrega, superior a 55 kW, son menores que los costes de operación de la unidad DE para los valores de potencia que está generando, pero hay dos horas (2 y 3) donde los costes de operación de la unidad DE favorece la disminución de los costes de operación de la microrred.
- Se debe destacar el comportamiento del BESS, el cual está entregando energía a la microrred tres horas más que en el caso 1 y valores de potencia más altos, lo que permite reducir la energía proporcionada por la MT en cada instante, por lo que asume un papel importante en la aportación de la reserva rodante.

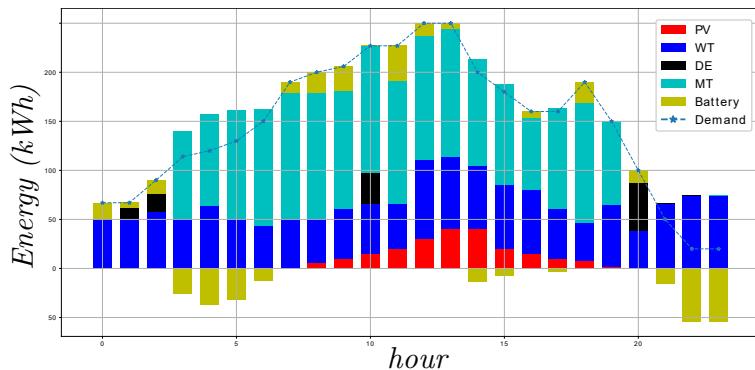


Figura 4.12 Solución caso de estudio 3. Programación Horaria de las Unidades Generadoras, extraída de [2].

La Figura muestra el comportamiento del BESS (las barras representan el SOC, la línea roja la potencia suministrada o absorbida por el BESS en cada instante).

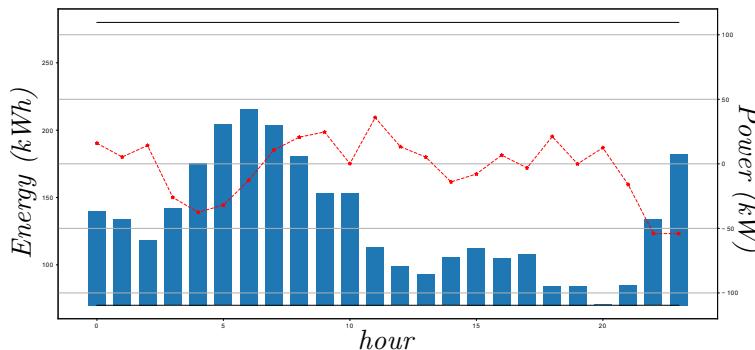


Figura 4.13 Gestión de la batería. Caso de estudio 3, extraída de [2].

4.3.5 Conclusiones

En esta Sección se ha presentado el diseño de un EMS para una microrred. Propone un enfoque evolutivo. A la vista de los resultados obtenidos, se plantean los principales aportes:

1. Se formula un GA para resolver el problema de la Programación Horaria de las Unidades de Generación y Almacenamiento, en un entorno estocástico a corto plazo, 24 horas en adelante, en una microrred que puede operar conectada a la red o de forma aislada, siendo este el caso más desfavorable.
2. Propone tres modos de operación de la microrred y formula un problema de optimización diferente para cada uno. Las funciones objetivo plantean minimizar el coste

total de operación de la microred, considerando criterios económicos, ambientales y de confiabilidad.

3. Cuando se supone el modo de operación económico, el GA proporciona una solución que prioriza la generación de la unidad diésel (DE) para bajos valores de demanda de potencia, mientras que para altos valores de potencia demandada prioriza la unidad que utiliza gas (MT). Este resultado se corresponde con la relación potencia/coste en estas unidades.
4. Cuando se minimiza el coste de la emisión de gases de efecto invernadero (modo ecológico), la solución que proporciona el GA disminuye la entrega de potencia de la unidad diésel (DE) a valores inferiores a 10 kW, mientras que aumenta la potencia generada de la MT, obteniendo valores entre 60 y 150 kW. Por tanto, este resultado provoca menor uso del generador diésel (DE), cuyos costes de emisión son mayores. Adicionalmente la contribución del BESS provoca que en 2 horas no haya aportes del DE y en una hora las unidades controlables se desconectan del sistema.
5. Cuando se supone el modo de operación robusto la solución aportada por el GA logra minimizar el coste total de operación y mantenimiento de la microred, garantizando el funcionamiento confiable en isla en un 99,73 %.
6. El GA es efectivo para estimar y programar el aporte de potencia de reserva rodante de las unidades de generación controlables. Prioriza la entrega de potencia de la MT, tanto en tiempo de conexión como en valores de potencia, con respecto al DE. Es significativo el aporte del BESS, con valores de potencia entregada por encima de 20 kW en horario de máxima demanda. Este resultado permite garantizar el funcionamiento en isla de la microred en un 99,73 %.
7. La solución aportada por el GA a la utilización de la reserva rodante para dar respuesta al error en la estimación de la demanda en el modo de operación robusto significó un incremento del 3,06 % en el coste de operación de la microred, con respecto al modo de operación económico.

5 Conclusiones

Esta tesis se ha centrado en resolver el problema de la gestión óptima de los recursos de generación y almacenamiento de energía en una microrred. Presenta un modelo de estos sistemas de energía que contienen unidades de generación controlables, fuentes de energía renovables, sistemas de almacenamiento de energía por baterías y demanda variable. Propone dos algoritmos con diferentes enfoques de solución para dar respuesta al problema estudiado.

A continuación se presentan las principales contribuciones y limitaciones derivadas de los resultados obtenidos, así como propuestas de futuros trabajos.

5.1 Contribuciones

1. Presenta una metodología para gestionar de forma óptima los recursos de generación y almacenamiento en una microrred que opera de forma aislada, siendo este modo de funcionamiento el más desfavorable, en un horizonte de programación 24 horas en adelante, considerando la incertidumbre asociada a la predicción de la demanda.
2. Propone utilizar la herramienta de Programación Horaria de las Unidades de Generación y Almacenamiento. Plantea un problema de optimización cuyo objetivo principal es minimizar el coste total de operación de la microrred, en un entorno estocástico. Incorpora restricciones de confiabilidad al problema que garantice el funcionamiento en isla de la microrred.
3. En esta Tesis, para garantizar el funcionamiento en isla de la microrred, se considera la premisa que la microrred debe disponer suficiente reserva rodante, aportada por las unidades de generación controlables (MT y DE) y el BESS, para satisfacer la demanda estimada local en todo instante de tiempo.
4. Propone resolver el problema de la Programación Horaria de las Unidades de Generación y Almacenamiento, considerando tres etapas:
 - a) Primero, observación, análisis y pronóstico de la demanda. Utiliza la herramienta ARMA.

- b) Segundo, determina la Asignación de las Unidades Generadoras que van a estar encendidas y apagadas cada hora en el horizonte de programación. En este problema se garantiza que la reserva rodante aportada por las unidades de generación controlables (MT y DE) y el BESS, es capaz de cubrir el error de estimación en un 99,73 %, lo que asegura el funcionamiento en isla de la microrred.
- c) Tercero, controla los desbalances de potencia provocados por la diferencia entre la potencia real demandada y la estimada en cada instante de tiempo t , en la operación en tiempo real de la microrred. Por tanto, reajusta los valores de reserva rodante que deben aportar las unidades de generación controlables (MT y DE) y el BESS, para cubrir el error en la predicción de la demanda. Entonces, asigna la potencia a las unidades generadoras (ED), garantizando el funcionamiento en isla de la microrred en un 99,73 %.
5. Propone dos algoritmos para resolver el problema de la Programación Horaria de las Unidades de Generación y Almacenamiento en una microrred:
- a) El primer algoritmo propone un enfoque clásico basado en MILP y el segundo algoritmo utiliza un enfoque evolutivo, en este caso un Algoritmo Genético.
 - b) Ambos algoritmos:
 - Incluyen en el modelado de la carga de la microrred el error en la predicción de la curva de demanda cada hora, en un horizonte de programación 24 horas en adelante.
 - Incorporan en el problema restricciones asociadas a la estimación de la potencia de reserva rodante, aportada por las unidades generadoras despachables y el BESS presentes en la microrred con el objetivo de mantener el equilibrio entre generación y demanda.
 - Incorporan restricciones de confiabilidad que garantizan el funcionamiento en isla de la microrred.
6. Los dos algoritmos son validados en una microrred híbrida que opera de forma aislada, formada por un generador diésel y una microturbina como unidades controladas, una turbina eólica y una planta fotovoltaica como fuentes de energía renovables no controladas y un sistema de almacenamiento de energía por baterías.
7. Los resultados de las simulaciones muestran que los algoritmos garantizan la confiabilidad de la operación de la microrred, al considerar que la reserva rodante asociada a las unidades de generación despachables cubre el error en la predicción de la demanda en un 99,73 %.

8. En el trabajo de investigación se estudia la influencia de variar los parámetros de la batería en la solución del problema de optimización planteado, para ello se proponen varios casos de estudio. La mejor solución encontrada por el algoritmo fue cuando se utiliza el 80 % de la energía eléctrica total almacenada en la batería (SOC) de su capacidad total, es decir, sin superar los límites técnicos establecidos por el fabricante. Esta propuesta logra disminuir en un 8 % el coste de operación de la microrred.

5.2 Principales limitaciones

1. Los dos algoritmos incorporan en el modelo a optimizar el error asociado a la predicción de la demanda, pero la generación de las fuentes de energía renovable en las próximas 24 horas, tanto eólica como fotovoltaica, se considera exactamente conocida, es decir, no se consideran las incertidumbres asociadas a ellas.
2. En el algoritmo 2, el tiempo que se requiere para la aplicación del Algoritmo Genético en tiempo real es de baja eficiencia.
3. Modificar el rango del SOC de la batería provoca que este sistema se degrade de forma diferente a lo planteado en la ficha técnica dada por el fabricante y por tanto, afectara la vida útil del sistema.

El caso de estudio no tiene en cuenta el efecto que provoca aumentar la profundidad de descarga de la batería en los ciclos de carga y descarga de este equipo. En este caso, la batería dispondrá de menos ciclos útiles de vida, por descargar la batería con un porcentaje mayor. Por tanto, no se tiene en cuenta este efecto en el coste de degradación del sistema de almacenamiento, que posiblemente exigirá reemplazos de sus componentes, con sus respectivos costes, o incluso su reemplazo antes del tiempo previsto. Aspectos estos, que influirán en el coste de operación de la microrred.

5.3 Futuros trabajos

1. Considerar en trabajos futuros las incertidumbres asociada a las fuentes de energía renovables (PV y WT). Se puede establecer un procedimiento similar al utilizado para estimar el error asociado a la incertidumbre de la demanda, estimando las perturbaciones como gaussianas.
2. Considerando los beneficios del enfoque evolutivo propuesto, varias mejoras se proponen para trabajos futuros:
 - Aumentar la confiabilidad de los resultados, para ello se propone incorporar un modelo más exacto del BESS, que considere los efectos de la degradación de la batería.
 - En este misma línea de mejoras, se propone también calcular un pronóstico del precio de la electricidad a corto plazo para desarrollar una Programación horaria de las unidades generadoras que tome en cuenta este parámetro.
 - Realizar el estudio de este problema de optimización desarrollado, con un enfoque multiobjetivo.

- Comparar los resultados del proceso evolutivo propuesto en este trabajo con otros algoritmos metaheurísticos tales como: Evolución Diferencial (*Differential Evolution*, DE), Estrategias Evolutivas (*Evolution Strategies*, ES), y Optimización por Enjambres de Partículas (*Particle Swarm Optimization*, PSO).
3. Incluir en el problema de optimización el coste de degradación del BESS debido a los ciclos de carga y descarga de la batería, asociados a la profundidad de descarga a la que es sometida.

Bibliografía

- [1] L. Alvarado-Barrios, Á. R. del Nozal, J. B. Valerino, I. G. Vera, and J. L. Martínez-Ramos, “Stochastic unit commitment in microgrids: Influence of the load forecasting error and the availability of energy storage,” *Renewable Energy*, vol. 146, pp. 2060–2069, 2020.
- [2] L. Alvarado-Barrios, A. Rodríguez del Nozal, A. Tapia, J. L. Martínez-Ramos, and D. Reina, “An evolutionary computational approach for the problem of unit commitment and economic dispatch in microgrids under several operation modes,” *Energies*, vol. 12, no. 11, p. 2143, 2019.
- [3] V. M. Raj and S. Chanana, “Fuel Cost Optimization of an Islanded Microgrid Considering Environmental Impact,” *Journal of Clean Energy Technologies*, vol. 4, no. 2, pp. 120–124, 2016.
- [4] P. Nejat, F. Jomehzadeh, M. M. Taheri, M. Gohari, and M. Z. A. Majid, “A global review of energy consumption, co2 emissions and policy in the residential sector (with an overview of the top ten co2 emitting countries),” *Renewable and sustainable energy reviews*, vol. 43, pp. 843–862, 2015.
- [5] C. Gerbaulet, C. von Hirschhausen, C. Kemfert, C. Lorenz, and P.-Y. Oei, “European electricity sector decarbonization under different levels of foresight,” *Renewable energy*, vol. 141, pp. 973–987, 2019.
- [6] S. Pye, P.-H. Li, I. Keppo, and B. O’Gallachoir, “Technology interdependency in the united kingdom’s low carbon energy transition,” *Energy Strategy Reviews*, vol. 24, pp. 314–330, 2019.
- [7] F. H. Malik and M. Lehtonen, “A review: Agents in smart grids,” *Electric Power Systems Research*, vol. 131, pp. 71–79, 2016.
- [8] S. Kakran and S. Chanana, “Smart operations of smart grids integrated with distributed generation: A review,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 524–535, 2018.

- [9] N. E. Agency, *The Costs of Decarbonisation*, 2019. [Online]. Available: <https://www.oecd-ilibrary.org/content/publication/9789264312180-en>
- [10] P. M. Connor, P. E. Baker, D. Xenias, N. Balta-Ozkan, C. J. Axon, and L. Cipcigan, “Policy and regulation for smart grids in the united kingdom,” *Renewable and Sustainable Energy Reviews*, vol. 40, pp. 269–286, 2014.
- [11] Y. Yang, S. Bremner, C. Menictas, and M. Kay, “Battery energy storage system size determination in renewable energy systems: A review,” *Renewable and Sustainable Energy Reviews*, vol. 91, pp. 109–125, 2018.
- [12] X. Tan, Q. Li, and H. Wang, “Advances and trends of energy storage technology in microgrid,” *International Journal of Electrical Power & Energy Systems*, vol. 44, no. 1, pp. 179–191, 2013.
- [13] H. Wen and W. Zhu, “Control and protection of dc microgrid with battery energy storage system,” in *2016 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*. IEEE, 2016, pp. 1–6.
- [14] L. Meng, E. R. Sanseverino, A. Luna, T. Dragicevic, J. C. Vasquez, and J. M. Guerrero, “Microgrid supervisory controllers and energy management systems: A literature review,” *Renewable and Sustainable Energy Reviews*, vol. 60, pp. 1263–1273, 2016.
- [15] D. Wu, F. Tang, T. Dragicevic, J. C. Vasquez, and J. M. Guerrero, “Autonomous active power control for islanded ac microgrids with photovoltaic generation and energy storage system,” *IEEE Transactions on energy conversion*, vol. 29, no. 4, pp. 882–892, 2014.
- [16] I. Serban and C. Marinescu, “Control strategy of three-phase battery energy storage systems for frequency support in microgrids and with uninterrupted supply of local loads,” *IEEE Transactions on Power Electronics*, vol. 29, no. 9, pp. 5010–5020, 2013.
- [17] Z. Xu, X. Guan, Q.-S. Jia, J. Wu, D. Wang, and S. Chen, “Performance analysis and comparison on energy storage devices for smart building energy management,” *IEEE Transactions on Smart Grid*, vol. 3, no. 4, pp. 2136–2147, 2012.
- [18] S. Parhizi, H. Lotfi, A. Khodaei, and S. Bahramirad, “State of the art in research on microgrids: A review.” *Ieee Access*, vol. 3, no. 1, pp. 890–925, 2015.
- [19] D. E. Olivares, A. Mehrizi-Sani, A. H. Etemadi, C. A. Cañizares, R. Iravani, M. Kazemani, A. H. Hajimiragha, O. Gomis-Bellmunt, M. Saeedifard, R. Palma-Behnke *et al.*, “Trends in microgrid control,” *IEEE Transactions on smart grid*, vol. 5, no. 4, pp. 1905–1919, 2014.
- [20] M. Soshinskaya, W. H. Crijns-Graus, J. M. Guerrero, and J. C. Vasquez, “Microgrids: Experiences, barriers and success factors,” *Renewable and Sustainable Energy Reviews*, vol. 40, pp. 659–672, 2014.

- [21] A. Ravichandran, P. Malysz, S. Siroouspour, and A. Emadi, “The critical role of microgrids in transition to a smarter grid: A technical review,” pp. 1–7, 2013.
- [22] N. Hatziargyriou, “H. asano, r. iravani, and c. marnay,“microgrids,”,” *Power and Energy Magazine, IEEE*, vol. 5, no. 4, pp. 78–94, 2007.
- [23] B. Lasseter, “Microgrids [distributed power generation],” in *2001 IEEE power engineering society winter meeting. Conference proceedings (Cat. No. 01CH37194)*, vol. 1. IEEE, 2001, pp. 146–149.
- [24] R. H. Lasseter, “Microgrids,” in *2002 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No. 02CH37309)*, vol. 1. IEEE, 2002, pp. 305–308.
- [25] N. D. Hatziargyriou, V. A. Kleftakis, and G. M. Papadimitriou, Christina N Messinis, “Microgrids in Distribution,” *Smart Grid Handbook*, pp. 1–24, 2016.
- [26] E. Bullich-Massagué, F. Díaz-González, M. Aragüés-Peñaiba, F. Girbau-Llistuella, P. Olivella-Rosell, and A. Sumper, “Microgrid clustering architectures,” *Applied Energy*, vol. 212, pp. 340–361, 2018.
- [27] W. Feng, M. Jin, X. Liu, Y. Bao, C. Marnay, C. Yao, and J. Yu, “A review of microgrid development in the united states—a decade of progress on policies, demonstrations, controls, and software tools,” *Applied energy*, vol. 228, pp. 1656–1668, 2018.
- [28] N. D. Hatziargyriou, V. A. Kleftakis, C. N. Papadimitriou, and G. M. Messinis, “Microgrids in distribution,” *Smart Grid Handarticle*, pp. 1–24, 2016.
- [29] M. F. Zia, E. Elbouchikhi, and M. Benbouzid, “Microgrids energy management systems: A critical review on methods, solutions, and prospects,” *Applied energy*, vol. 222, pp. 1033–1055, 2018.
- [30] W. Elsayed, Y. Hegazy, F. Bendary, and M. El-Bages, “Energy management of residential microgrids using random drift particle swarm optimization,” pp. 166–171, 2018.
- [31] I. G. Marneris, P. N. Biskas, and A. G. Bakirtzis, “Stochastic and deterministic unit commitment considering uncertainty and variability reserves for high renewable integration,” *Energies*, vol. 10, no. 1, p. 140, 2017.
- [32] I. E. Commission *et al.*, “Iec 61970: Energy management system application program interface (ems-api),” *International Electrotechnical Commission (IEC): Geneva, Switzerland*, 2004.
- [33] N. Hatziargyriou, *Microgrids: architectures and control*. John Wiley & Sons, 2014.
- [34] C. Bordons, F. Garcia-Torres, and M. A. Ridao, *Model Predictive Control of Microgrids*. Springer, Cham, 2019.

- [35] C. Chen, S. Duan, T. Cai, B. Liu, and G. Hu, “Smart energy management system for optimal microgrid economic operation,” *IET renewable power generation*, vol. 5, no. 3, pp. 258–267, 2011.
- [36] A. A. Khan, M. Naeem, M. Iqbal, S. Qaisar, and A. Anpalagan, “A compendium of optimization objectives, constraints, tools and algorithms for energy management in microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 58, pp. 1664–1683, 2016.
- [37] O. Boqtob, H. El Moussaoui, H. El Markhi, and T. Lamhamdi, “Microgrid energy management system: a state-of-the-art review.” *Journal of Electrical Systems*, vol. 15, no. 1, 2019.
- [38] N. P. Padhy, “Unit commitment-a bibliographical survey,” *IEEE Transactions on Power Systems*, vol. 19, no. 2, pp. 1196–1205, May 2004.
- [39] M. Nemati, M. Braun, and S. Tenbohlen, “Optimization of unit commitment and economic dispatch in microgrids based on genetic algorithm and mixed integer linear programming,” *Applied Energy*, vol. 210, pp. 944 – 963, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0306261917308723>
- [40] J. J. Shaw, “A direct method for security-constrained unit commitment,” *IEEE Transactions on Power Systems*, vol. 10, no. 3, pp. 1329–1342, Aug 1995.
- [41] X. Lei, E. Lerch, and C. Xie, “Frequency security constrained short-term unit commitment,” *Electric Power Systems Research*, vol. 60, no. 3, pp. 193 – 200, 2002. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378779601001778>
- [42] S. Reddy, L. K. Panwar, B. Panigrahi, R. Kumar, and A. Alsumaiti, “Binary grey wolf optimizer models for profit based unit commitment of price-taking genco in electricity market,” *Swarm and evolutionary computation*, vol. 44, pp. 957–971, 2019.
- [43] I. Blanco and J. M. Morales, “An efficient robust solution to the two-stage stochastic unit commitment problem,” *IEEE Transactions on Power Systems*, vol. 32, no. 6, pp. 4477–4488, 2017.
- [44] Q. Wang, J. Wang, and Y. Guan, “Stochastic unit commitment with uncertain demand response,” *IEEE Transactions on power systems*, vol. 28, no. 1, pp. 562–563, 2013.
- [45] P. Li and D. Xu, “Optimal operation of microgrid based on improved binary particle swarm optimization algorithm with double-structure coding,” pp. 3141–3146, 2014.
- [46] S. Y. Abujarad, M. Mustafa, and J. Jamian, “Recent approaches of unit commitment in the presence of intermittent renewable energy resources: A review,” *Renewable and Sustainable Energy Reviews*, vol. 70, pp. 215–223, 2017.

- [47] P. Che and G. Shi, "An milp approach for a profit-based unit commitment problem with emissions penalty," in *The 26th Chinese Control and Decision Conference (2014 CCDC)*. IEEE, 2014, pp. 4474–4477.
- [48] N. Zaree and V. Vahidinasab, "An milp formulation for centralized energy management strategy of microgrids," in *2016 Smart Grids Conference (SGC)*. IEEE, 2016, pp. 1–8.
- [49] D. Zhang, S. Liu, and L. G. Papageorgiou, "Fair cost distribution among smart homes with microgrid," *Energy Conversion and Management*, vol. 80, pp. 498–508, 2014.
- [50] M. Q. Wang and H. Gooi, "Spinning reserve estimation in microgrids," *IEEE Transactions on Power Systems*, vol. 26, no. 3, pp. 1164–1174, 2011.
- [51] G. Liu, M. Starke, B. Xiao, X. Zhang, and K. Tomsovic, "Microgrid optimal scheduling with chance-constrained islanding capability," *Electric Power Systems Research*, vol. 145, pp. 197–206, 2017.
- [52] B. Fu, C. Ouyang, C. Li, J. Wang, and E. Gul, "An improved mixed integer linear programming approach based on symmetry diminishing for unit commitment of hybrid power system," *Energies*, vol. 12, no. 5, 2019. [Online]. Available: <http://www.mdpi.com/1996-1073/12/5/833>
- [53] H. Z. Abidin and N. M. Din, "Sensor node placement based on lexicographic minimax," in *2012 International Symposium on Telecommunication Technologies*. IEEE, 2012, pp. 82–87.
- [54] M. A. O. Vazquez, "Optimizing the spinning reserve requirements," Ph.D. dissertation, University of Manchester, 2006.
- [55] H. D. Sherali and J. C. Smith, "Improving discrete model representations via symmetry considerations," *Management Science*, vol. 47, no. 10, pp. 1396–1407, 2001.
- [56] M. Jin, W. Feng, C. Marnay, and C. Spanos, "Microgrid to enable optimal distributed energy retail and end-user demand response," *Applied Energy*, vol. 210, pp. 1321–1335, 2018.
- [57] R. Garmabdar, M. Moghimi, F. Yang, E. Gray, and J. Lu, "Battery energy storage capacity optimisation for grid-connected microgrids with distributed generators," in *Universities Power Engineering Conference (AUPEC), 2017 Australasian*. IEEE, 2017, pp. 1–6.
- [58] D. Liu and Q. Wei, "Policy iteration adaptive dynamic programming algorithm for discrete-time nonlinear systems," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 3, pp. 621–634, 2013.

- [59] B. Heymann, J. F. Bonnans, P. Martinon, F. J. Silva, F. Lanas, and G. Jiménez-Estévez, “Continuous optimal control approaches to microgrid energy management,” *Energy Systems*, vol. 9, no. 1, pp. 59–77, 2018.
- [60] L. N. An and T. Quoc-Tuan, “Optimal energy management for grid connected microgrid by using dynamic programming method,” in *2015 IEEE Power & Energy Society General Meeting*. IEEE, 2015, pp. 1–5.
- [61] H. Li, C. Zang, P. Zeng, H. Yu, and Z. Li, “A genetic algorithm-based hybrid optimization approach for microgrid energy management,” pp. 1474–1478, 2015.
- [62] K.-H. Jo and M.-K. Kim, “Stochastic unit commitment based on multi-scenario tree method considering uncertainty,” *Energies*, vol. 11, no. 4, p. 740, 2018.
- [63] M. Nemati, K. Bennimar, S. Tenbohlen, L. Tao, H. Mueller, and M. Braun, “Optimization of microgrids short term operation based on an enhanced genetic algorithm,” pp. 1–6, 2015.
- [64] A. Askarzadeh, “A memory-based genetic algorithm for optimization of power generation in a microgrid,” *IEEE transactions on sustainable energy*, vol. 9, no. 3, pp. 1081–1089, 2018.
- [65] H. Liang and H. Gooi, “Unit commitment in microgrids by improved genetic algorithm,” pp. 842–847, 2010.
- [66] S. Yang, “Genetic algorithms with memory-and elitism-based immigrants in dynamic environments,” *Evolutionary Computation*, vol. 16, no. 3, pp. 385–416, 2008.
- [67] D. N. Simopoulos, S. D. Kavatza, and C. D. Vournas, “Unit commitment by an enhanced simulated annealing algorithm,” *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 68–76, 2006.
- [68] P. Li, D. Xu, Z. Zhou, W.-J. Lee, and B. Zhao, “Stochastic optimal operation of microgrid based on chaotic binary particle swarm optimization.” *IEEE Trans. Smart Grid*, vol. 7, no. 1, pp. 66–73, 2016.
- [69] D. Arcos-Aviles, J. Pascual, F. Guinjoan, L. Marroyo, P. Sanchis, and M. P. Marietta, “Low complexity energy management strategy for grid profile smoothing of a residential grid-connected microgrid using generation and demand forecasting,” *Applied energy*, vol. 205, pp. 69–84, 2017.
- [70] J. Yin and D. Zhao, “Fuzzy stochastic unit commitment model with wind power and demand response under conditional value-at-risk assessment,” *Energies*, vol. 11, no. 2, p. 341, 2018.
- [71] E. De Santis, A. Rizzi, and A. Sadeghian, “Hierarchical genetic optimization of a fuzzy logic system for energy flows management in microgrids,” *Applied Soft Computing*, vol. 60, pp. 135–149, 2017.

- [72] H. Quan, D. Srinivasan, and A. Khosravi, "Incorporating wind power forecast uncertainties into stochastic unit commitment using neural network-based prediction intervals," *IEEE transactions on neural networks and learning systems*, vol. 26, no. 9, pp. 2123–2135, 2015.
- [73] T. Wang, X. He, and T. Deng, "Neural networks for power management optimal strategy in hybrid microgrid," *Neural Computing and Applications*, vol. 31, no. 7, pp. 2635–2647, 2019.
- [74] S. Zhang and A. Constantinides, "Lagrange programming neural networks," *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, vol. 39, no. 7, pp. 441–452, 1992.
- [75] S. Boyd, S. P. Boyd, and L. Vandenberghe, *Convex optimization*. Cambridge university press, 2004.
- [76] D. Lew, M. Milligan, G. Jordan, and R. Piwko, "Value of wind power forecasting," National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., 2011.
- [77] T. Senju, K. Shimabukuro, K. Uezato, and T. Funabashi, "A fast technique for unit commitment problem by extended priority list," *IEEE Transactions on Power Systems*, vol. 18, no. 2, pp. 882–888, 2003.
- [78] A. Ghasemi, "Coordination of pumped-storage unit and irrigation system with intermittent wind generation for intelligent energy management of an agricultural microgrid," *Energy*, vol. 142, pp. 1–13, 2018.
- [79] G. Cau, D. Cocco, M. Petrollese, S. K. Kær, and C. Milan, "Energy management strategy based on short-term generation scheduling for a renewable microgrid using a hydrogen storage system," *Energy Conversion and Management*, vol. 87, pp. 820–831, 2014.
- [80] G. Verbic and C. A. Canizares, "Probabilistic optimal power flow in electricity markets based on a two-point estimate method," *IEEE transactions on Power Systems*, vol. 21, no. 4, pp. 1883–1893, 2006.
- [81] A. Z. Alabedin, E. El-Saadany, and M. Salama, "Generation scheduling in microgrids under uncertainties in power generation," in *2012 IEEE electrical power and energy conference*. IEEE, 2012, pp. 133–138.
- [82] A. Y. Saber and G. K. Venayagamoorthy, "Resource scheduling under uncertainty in a smart grid with renewables and plug-in vehicles," *IEEE systems journal*, vol. 6, no. 1, pp. 103–109, 2011.
- [83] C. De Boor, C. De Boor, E.-U. Mathématicien, C. De Boor, and C. De Boor, *A practical guide to splines*. Springer-Verlag New York, 1978, vol. 27.
- [84] E. F. Camacho and C. B. Alba, *Model predictive control*. Springer Science & Business Media, 2013.

- [85] C. Bordons, F. Garcia-Torres, and M. A. Ridao, *Model Predictive Control of Microgrids*. Springer, 2020.
- [86] R. Palma-Behnke, C. Benavides, F. Lanas, B. Severino, L. Reyes, J. Llanos, and D. Sáez, “A microgrid energy management system based on the rolling horizon strategy,” *IEEE Transactions on Smart Grid*, vol. 4, no. 2, pp. 996–1006, 2013.
- [87] K. Utkarsh, D. Srinivasan, A. Trivedi, W. Zhang, and T. Reindl, “Distributed model-predictive real-time optimal operation of a network of smart microgrids,” *IEEE Transactions on Smart Grid*, vol. 10, no. 3, pp. 2833–2845, 2018.
- [88] J. Silvente, G. M. Kopanos, E. N. Pistikopoulos, and A. Espuña, “A rolling horizon optimization framework for the simultaneous energy supply and demand planning in microgrids,” *Applied Energy*, vol. 155, pp. 485 – 501, 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0306261915007230>
- [89] K. Utkarsh, A. Trivedi, D. Srinivasan, and T. Reindl, “A consensus-based distributed computational intelligence technique for real-time optimal control in smart distribution grids,” *IEEE Transactions on Emerging Topics in Computational Intelligence*, vol. 1, no. 1, pp. 51–60, 2016.
- [90] X. Gandibleux, *Multiple criteria optimization: state of the art annotated bibliographic surveys*. Springer Science & Business Media, 2006, vol. 52.
- [91] A. Chaouachi, R. M. Kamel, R. Andoulsi, and K. Nagasaka, “Multiobjective intelligent energy management for a microgrid,” *IEEE Transactions on Industrial Electronics*, vol. 60, no. 4, pp. 1688–1699, 2012.
- [92] E. Zitzler, J. Knowles, and L. Thiele, “Quality assessment of pareto set approximations,” in *Multiobjective Optimization*. Springer, 2008, pp. 373–404.
- [93] K. Deb, “Multi-objective optimizations,” in *Search methodologies. Introductory tutorials in optimization and decision support technique*. Springer, 2014, pp. 403–449.
- [94] M. L. Di Silvestre, G. Graditi, and E. R. Sanseverino, “A generalized framework for optimal sizing of distributed energy resources in micro-grids using an indicator-based swarm approach,” *IEEE Transactions on Industrial Informatics*, vol. 10, no. 1, pp. 152–162, 2013.
- [95] B. Zhao, X. Zhang, J. Chen, C. Wang, and L. Guo, “Operation optimization of standalone microgrids considering lifetime characteristics of battery energy storage system,” *IEEE transactions on sustainable energy*, vol. 4, no. 4, pp. 934–943, 2013.
- [96] Y. Katsigiannis, P. Georgilakis, and E. Karapidakis, “Multiobjective genetic algorithm solution to the optimum economic and environmental performance problem of small autonomous hybrid power systems with renewables,” *IET Renewable Power Generation*, vol. 4, no. 5, pp. 404–419, 2010.

- [97] W.-Y. Chiu, H. Sun, and H. V. Poor, “A multiobjective approach to multimicrogrid system design,” *IEEE Transactions on Smart Grid*, vol. 6, no. 5, pp. 2263–2272, 2015.
- [98] S. Baldi, A. Karagevrekis, I. T. Michailidis, and E. B. Kosmatopoulos, “Joint energy demand and thermal comfort optimization in photovoltaic-equipped interconnected microgrids,” *Energy Conversion and Management*, vol. 101, pp. 352–363, 2015.
- [99] G.-C. Luh, C.-H. Chueh, and W.-W. Liu, “Moia: multi-objective immune algorithm,” *Engineering Optimization*, vol. 35, no. 2, pp. 143–164, 2003.
- [100] I. T. Michailidis, S. Baldi, E. B. Kosmatopoulos, M. F. Pichler, J. R. Santiago, and F. Miranda, “Improving energy savings and thermal comfort in large-scale buildings via adaptive optimization,” in *Control Theory: Perspectives, Applications and Developments*. Nova Science Publishers, 2015, pp. 315–335.
- [101] L. I. Minchala-Avila, L. E. Garza-Castañón, A. Vargas-Martínez, and Y. Zhang, “A review of optimal control techniques applied to the energy management and control of microgrids,” *Procedia Computer Science*, vol. 52, pp. 780–787, 2015.
- [102] S. S. Pappas, L. Ekonomou, D. C. Karamousantas, G. Chatzarakis, S. Katsikas, and P. Liatsis, “Electricity demand loads modeling using autoregressive moving average (arma) models,” *Energy*, vol. 33, no. 9, pp. 1353–1360, 2008.
- [103] D. C. Hill, D. McMillan, K. R. Bell, and D. Infield, “Application of auto-regressive models to uk wind speed data for power system impact studies,” *IEEE Transactions on Sustainable Energy*, vol. 3, no. 1, pp. 134–141, 2012.
- [104] J. K. Patel and C. B. Read, *Handbook of the normal distribution*. CRC Press, 1996, vol. 150.
- [105] F. Pukelsheim, “The three sigma rule,” *The American Statistician*, vol. 48, no. 2, pp. 88–91, 1994.
- [106] F. Lasnier and T. G. Ang, “Photovoltaic engineering handarticle,” 1990.
- [107] A. Tapia, G. Tapia, J. X. Ostolaza, and J. R. Saenz, “Modeling and control of a wind turbine driven doubly fed induction generator,” *IEEE Transactions on energy conversion*, vol. 18, no. 2, pp. 194–204, 2003.
- [108] Y. Lei, A. Mullane, G. Lightbody, and R. Yacamini, “Modeling of the wind turbine with a doubly fed induction generator for grid integration studies,” *IEEE transactions on energy conversion*, vol. 21, no. 1, pp. 257–264, 2006.
- [109] N. W. Miller, J. J. Sanchez-Gasca, W. W. Price, and R. W. Delmerico, “Dynamic modeling of ge 1.5 and 3.6 mw wind turbine-generators for stability simulations,” vol. 3, pp. 1977–1983, 2003.

- [110] M. Deshmukh and S. Deshmukh, "Modeling of hybrid renewable energy systems," *Renewable and Sustainable Energy Reviews*, vol. 12, no. 1, pp. 235 – 249, 2008. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1364032106001134>
- [111] F. A. Mohamed and H. N. Koivo, "System modelling and online optimal management of microgrid using mesh adaptive direct search," *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 5, pp. 398 – 407, 2010. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0142061509001768>
- [112] ———, "Online management of microgrid with battery storage using multiobjective optimization," pp. 231–236, April 2007.
- [113] Y. Rebours and D. Kirschen, "What is spinning reserve," *The University of Manchester*, vol. 174, p. 175, 2005.
- [114] ———, "What is spinning reserve," *The University of Manchester*, vol. 174, no. 175, 2005.
- [115] M. A. Ortega-Vazquez and D. S. Kirschen, "Estimating the spinning reserve requirements in systems with significant wind power generation penetration," *IEEE Transactions on Power Systems*, vol. 24, no. 1, pp. 114–124, 2009.
- [116] ———, "Optimizing the spinning reserve requirements using a cost/benefit analysis," *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 24–33, 2007.
- [117] R. N. Allan *et al.*, *Reliability evaluation of power systems*. Springer Science & Business Media, 2013.
- [118] F. Bouffard and F. D. Galiana, "An electricity market with a probabilistic spinning reserve criterion," *IEEE Transactions on Power Systems*, vol. 19, no. 1, pp. 300–307, 2004.
- [119] D. N. Simopoulos, S. D. Kavatza, and C. D. Vournas, "Reliability constrained unit commitment using simulated annealing," *IEEE Transactions on Power Systems*, vol. 21, no. 4, pp. 1699–1706, 2006.
- [120] J. Wang, X. Wang, and Y. Wu, "Operating reserve model in the power market," *IEEE Transactions on Power systems*, vol. 20, no. 1, pp. 223–229, 2005.
- [121] M. A. Ortega-Vazquez, D. S. Kirschen, and D. Pudjianto, "Optimising the scheduling of spinning reserve considering the cost of interruptions," *IEE Proceedings-Generation, Transmission and Distribution*, vol. 153, no. 5, pp. 570–575, 2006.
- [122] A. Azmy and I. Erlich, "Online optimal management of pem fuel cells using neural networks," pp. 1337 Vol. 2–, June 2005.
- [123] S. Ororo and M. Irving, "Large scale unit commitment using a hybrid genetic algorithm," *International Journal of Electrical Power & Energy Systems*, vol. 19, no. 1, pp. 45 – 55, 1997. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0142061596000282>

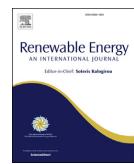
- [124] A. J. Wood and B. F. Wollenberg, “Power generation, operation and control,” 1984.
- [125] G. Liu and K. Tomsovic, “A full demand response model in co-optimized energy and reserve market,” *Electric Power Systems Research*, vol. 111, pp. 62–70, 2014.
- [126] J. Wang, N. E. Redondo, and F. D. Galiana, “Demand-side reserve offers in joint energy/reserve electricity markets,” *IEEE Transactions on Power Systems*, vol. 18, no. 4, pp. 1300–1306, 2003.
- [127] M. Farrokhabadi, C. A. Cañizares, and K. Bhattacharya, “Unit commitment for isolated microgrids considering frequency control,” *IEEE Transactions on Smart Grid*, vol. 9, no. 4, pp. 3270–3280, 2018.
- [128] P. A. Ruiz, C. R. Philbrick, E. Zak, K. W. Cheung, and P. W. Sauer, “Uncertainty management in the unit commitment problem,” *IEEE Transactions on Power Systems*, vol. 24, no. 2, pp. 642–651, 2009.
- [129] S. Ramabhotla, S. Bayne, and M. Giesselmann, “Operation and maintenance cost optimization in the grid connected mode of microgrid,” in *Green Technologies Conference (GreenTech), 2016 IEEE*. IEEE, 2016, pp. 56–61.
- [130] M. Arzamendia, D. Gregor, D. G. Reina, and S. L. Toral, “An evolutionary approach to constrained path planning of an autonomous surface vehicle for maximizing the covered area of ypacarai lake,” *Soft Computing*, pp. 1–12, 2017.
- [131] D. Gutiérrez-Reina, V. Sharma, I. You, and S. Toral, “Dissimilarity metric based on local neighboring information and genetic programming for data dissemination in vehicular ad hoc networks (vanets),” *Sensors*, vol. 18, no. 7, p. 2320, 2018.
- [132] Z. Michalewicz, *Genetic algorithms+ data structures= evolution programs*. Springer Science & Business Media, 2013.
- [133] J. H. Holland, *Genetic Algorithms and Adaptation*. Springer US, 1984. [Online]. Available: http://dx.doi.org/10.1007/978-1-4684-8941-5_21
- [134] S. Luke, *Essentials of Metaheuristics*, 1st ed. lulu.com, 2009, available at <http://cs.gmu.edu/~sean/books/metaheuristics/>. [Online]. Available: <http://cs.gmu.edu/~sean/book/metaheuristics/>
- [135] K. Deb and R. B. Agrawal, “Simulated binary crossover for continuous search space,” Tech. Rep., 1994.
- [136] A. Ter-Sarkisov and S. Marsland, “Convergence properties of two $\{\mu\} + \{\lambda\}$ evolutionary algorithms on onemax and royal roads test functions,” *arXiv preprint arXiv:1108.4080*, 2011.
- [137] F.-A. Fortin, F.-M. De Rainville, M.-A. Gardner, M. Parizeau, and C. Gagné, “DEAP: Evolutionary algorithms made easy,” *Journal of Machine Learning Research*, vol. 13, pp. 2171–2175, jul 2012.

- [138] G. D., “Evolutionary microgrid,” <https://github.com/Dany503/Evolutionary-Microgrids>, 2019.

Apendice

1 Artículos publicados

1.1 Renewable Energy (2020)



Stochastic unit commitment in microgrids: Influence of the load forecasting error and the availability of energy storage



Lázaro Alvarado-Barrios ^{a,*}, Álvaro Rodríguez del Nozal ^b, Juan Boza Valerino ^b, Ignacio García Vera ^a, Jose L. Martínez-Ramos ^b

^a Departamento de Ingeniería, Universidad Loyola Andalucía, Seville, Spain

^b Department of Electrical Engineering, Universidad de Sevilla, Seville, Spain

ARTICLE INFO

Article history:

Received 30 November 2018

Received in revised form

31 July 2019

Accepted 5 August 2019

Available online 9 August 2019

Keywords:

Microgrid

Distributed generation

Energy storage sources

Unit commitment problem

ABSTRACT

A Stochastic Model for the Unit Commitment (SUC) problem of a hybrid microgrid for a short period of 24 h is presented. The microgrid considered in the problem is composed of a wind turbine (WT), a photovoltaic plant (PV), a diesel generator (DE), a microturbine (MT) and a Battery Energy Storage System (BESS). The problem is addressed in three stages. First, based on the historical data of the demanded power in the microgrid, an ARMA model is used to obtain the demand prediction. Second, the 24-h-ahead SUC problem is solved, based on generators' constraints, renewable generation and demand forecast and the statistical distribution of the error in the demand estimation. In this problem, a spinning reserve of the dispatchable units is considered, able to cover the uncertainties in the demand estimation. In the third stage, once the SUC problem has been solved, a case study is established in real time, in which the demand estimation error in every moment is known. Therefore, the objective of this stage is to select the spinning reserve of the units in an optimal way to minimize the cost in the microgrid operation.

© 2019 Elsevier Ltd. All rights reserved.

1. Introduction

The International Committee of Large Electrical Networks (CIGRE) defines microgrids as: electrical distribution systems that contain distributed energy resources and loads (generators, storage devices and controllable loads) that can operate in a controlled way connected to the main network or isolated [1]. They make it possible to respond to the need to supply energy to isolated cities, islands or specific consumption, contributing to the improvement of service reliability, and to reduce losses and enhance the stability of the system [2,3].

Recently, several forms of energy storage with relative intensity have been studied, including: electrochemical batteries, air compressors, supercapacitors, flywheels and magnetic superconductors [4]. The energy storage system (ESS) is considered an indispensable element of a reliable microgrid because it provides significant benefits to the operation of microgrids both in isolated and grid-connected operation modes [5]. In the isolated operation mode,

the ESS can be used to ensure the balance between generation and load, reduce the operating cost by storing energy during the low-price period and discharging the accumulated energy during the high-price period, reducing the peak loads [3].

In particular, the battery energy storage system (BESS) has proven to be an efficient technology for applications related to power management and power quality in microgrids, e.g., covering consumption peaks [6], participating in active power control [7], flattening the load curve [8], participating in the frequency control [9], voltage control [10] and working as a reserve in the microgrid [11,12]. Therefore, the selection of the optimal size and the operation strategy, including the BESS loading/unloading cycle, is a priority to obtain the maximum benefit in the operation of the microgrid.

The Unit Commitment (UC), initially determines the programming of the units that must start and stop in order to respond to the required demand [13]. Once the UC has been carried out, the economic dispatch (ED) is responsible for assigning to the programmed units power to generate and to cover the demand in the most economical way, while satisfying the physical constraints of the generating units (power balance, power generation limits) [13,14]. Stochastic unit commitment

* Corresponding author.
E-mail address: lalvarado@uloyola.es (L. Alvarado-Barrios).

1.2 Energies (2019)

Article

An Evolutionary Computational Approach for the Problem of Unit Commitment and Economic Dispatch in Microgrids under Several Operation Modes

L. Alvarado-Barrios ^{1,*}, A. Rodríguez del Nozal ¹, A. Tapia ¹, J. L. Martínez-Ramos ² and D. G. Reina ³

¹ Departamento de Ingeniería, Universidad Loyola Andalucía, 41014 Seville, Spain; alvarordn@hotmail.com (A.R.d.N.); atapia@uloyola.es (A.T.)

² Electrical Engineering Department, University of Seville, 41092 Seville, Spain; jl.martinez.ramos@gmail.com

³ Electronic Engineering Department, University of Seville, 41092 Seville, Spain; dgutierrezreina@us.es

* Correspondence: lalvarado@uloyola.es

Received: 17 April 2019; Accepted: 30 May 2019; Published: 4 June 2019



Abstract: In the last decades, new types of generation technologies have emerged and have been gradually integrated into the existing power systems, moving their classical architectures to distributed systems. Despite the positive features associated to this paradigm, new problems arise such as coordination and uncertainty. In this framework, microgrids constitute an effective solution to deal with the coordination and operation of these distributed energy resources. This paper proposes a Genetic Algorithm (GA) to address the combined problem of Unit Commitment (UC) and Economic Dispatch (ED). With this end, a model of a microgrid is introduced together with all the control variables and physical constraints. To optimally operate the microgrid, three operation modes are introduced. The first two attend to optimize economical and environmental factors, while the last operation mode considers the errors induced by the uncertainties in the demand forecasting. Therefore, it achieves a robust design that guarantees the power supply for different confidence levels. Finally, the algorithm was applied to an example scenario to illustrate its performance. The achieved simulation results demonstrate the validity of the proposed approach.

Keywords: microgrids; Unit Commitment; Economic Dispatch; Genetic Algorithm

1. Introduction

The deregulation process in the energy sector has encouraged a transformation of the Electric Power Systems (EPS). EPS are defined as networks of electrical components deployed to supply, transfer, store and use electric power. Nevertheless, in the last decades, EPS are changing their classical scheme, which has been traditionally characterized by a centralized top-down operated architecture, to a distributed model. This new scheme is strongly characterized by an increasing integration of Renewable Energy Sources (RES) [1,2]. In this scenario of transformation, microgrids, which are defined as coordinated aggregations of loads and generation resources in medium and low voltage grids [3], play a fundamental role [4,5]. This is mainly due to their capability of integrating and exploiting RES, together with additional benefits, such as enhancing the entrance of electric vehicles [6]. Microgrids are generally composed by a certain set of loads, conventional and renewable generation units, and storage units, being these last components operated as independent and controllable units [7,8], either connected or disconnected from the grid [9].

The operation of a microgrid is performed by using Energy Management Systems (EMS) [10], which are responsible for commanding the local generation, storage and flexible demand resources.

EMS dispatches the active energy from RES and control the load consumption in the most optimal way. This management is normally carried out on the basis of an established criterion [11]. In this context, the problem of Unit Commitment (UC) represents an important tool to study the optimal scheduling of generation resources [12], contributing not only to improve the stability and reliability of the microgrid, but also reducing the environmental impact and the costs associated to the operation [13]. The UC consists of finding the most suitable schedule for coordinating the different generation and storage units to achieve a target objective, such as minimizing the cost or maximizing the benefits.

Once the UC is solved, the Economic Dispatch (ED) is responsible for assigning the generation reference to the programmed units, satisfying the power demand together with the physical constraints of the grid [14]. Sometimes, this problem is tackled considering the possible uncertainty in the power generated of the RES or the demand. Thus, this combined problem aims to deal with the variability of both the RES and the demand [1,7].

In general, the uncertainty in the UC problem is represented by the formulation of a set of scenarios, which are made on the basis of the predictions of the demand and the RES generation. In contrast, deterministic approaches are commonly used, where a single scenario is considered [15,16]. Given these features, stochastic approaches are crucial to address an optimal management of microgrids [17], which has motivated several studies in the literature [18–20]. These approaches contribute to the robustness of the solution, making them more appropriate to microgrid implementations.

Finally, it is worth pointing out the complexity of the combined UC and ED problem [21]. The schedule of the dispatchable generation units together with the management of the ESS, with the additional consideration of uncertainties in the demand forecasting generates a non-convex mathematical problem, which combines strong non-linearities and mixed integer formulation. Although some authors have proposed to linearize the objective functions, it introduces inaccuracies into the resulting operation cost. In addition, such linearization should be done at each operation point, which can result in a slow iterative procedure. Therefore, such approach can suffer from convergence and scalability problems for high dimensional scenarios. Similar to linear programming based approaches, metaheuristic algorithms such as evolutionary algorithms allow dealing with non-linearities in an effective way since the search engine is based on genetic operations (selection, crossover, and mutation) among potential solutions. Given these characteristics of the combined UC and ED problem, solving it in the most optimal way constitutes itself a challenge. Furthermore, it is important to note that small deviations in the solution might imply noticeable effects in the operational and maintenance costs of the microgrid, also affecting the level of emissions. For these reasons, the use of meta-heuristic approaches is of particular relevance.

The main contributions of this work are summarized:

- A new methodology is introduced to deal with the generation schedule problem of a microgrid where the demand forecasting is affected by uncertainties. This approach ensures the robustness of the algorithm at the expense of affecting the operational and environmental cost of the installation.
- The microgrid model includes several operation modes optimizing different aspects of the microgrid such as power cost, emissions, and robust operation with respect to the demand variability. Combined operation modes, where a combination of objective functions are used, are considered.
- An evolutionary approach for solving the UC and ED problems in microgrids is presented.

The paper is organized as follows. Section 2 presents the related work of current approaches that have addressed EMS in microgrids. Section 3 introduces the stochastic UC and ED problems in a microgrid. In Section 4, the different components of the microgrid are modeled in detail. Section 5 presents the operation modes of the considered microgrid. In Section 6, an evolutionary computational approach is proposed to address the problem. Section 7 contains the evaluation of the proposed approach through extensive simulations. Finally, in Section 8 some conclusions and remarks are drawn together with future work lines.

2. Related Work

An extensive review of the objectives, constraints and algorithms used in EMS for microgrids is addressed in [18], where the authors provided a brief summary of the main strategies used to tackle this problem: linear, non-linear, stochastic, dynamic and non-differential programming. In addition, a classification of the different optimization techniques reported in the literature is presented.

The UC problem is generally classified as Mixed Integer Non-Linear Programming (MINLP) [19,22,23]. An illustrative work is [22], where the authors proposed a profit-based UC problem with non-linear emissions penalty. This penalty has been transformed through a mixed-integer formulation, while the non-linearities of the fuel cost function are addressed by means of a piece-wise linearization. The proposed algorithm is used to solve several architectures, exhibiting good results. A very similar strategy is used in [23], where numerical results confirm the robustness of the approach. The authors of [24] proposed a MILP to determine a fair cost distribution among smart homes with microgrid, obtaining noticeable cost reductions and fair cost distribution among multiple homes under a set of test scenarios.

Despite of the high efficiency of MILP approaches, it is worth pointing out that the computational cost of these approaches increases drastically with the number of integer variables. To address this drawback, several proposals are discussed. In [25], a multi-step method is used to consider the combinatorial calculations of unit outage events. This method noticeably improves the calculations of the spinning reserve, while reducing the computational burden. The authors of [26] proposed the resolution of different scales separately, by means of a bottom-up approach, keeping track of the error. This strategy strongly reduces the computational time required to find an optimal solution without sacrificing the quality of the results. Therefore, it improves the capability of MILP approaches to address large-scale modelling of urban energy systems. In addition, in [27], the authors proposed an improved MILP to increase the efficiency of the approach for its application to big scale grids, where the results in different scales show a dramatic improvement in comparison with other MILP proposed in the literature. It is also relevant to highlight the capability of these approaches to address the energy optimization in city environments [28]. A relevant work is found in [29], where the scheduling problem of building energy supply is addressed to minimize the overall cost of the energy consumption. Mixed-Integer Quadratic Problem (MIQP) is also used to address the UC problem. An illustrative work can be found in [30], where the authors proposed an improved MIQP, which improves its efficiency by means of relaxation and decoupling techniques.

In addition to both MILP and MIQP approaches, a wide variety of optimization algorithms are proposed in the literature [31,32] to address this problem (see Table 1, where the most relevant works are summarized). The studied works present a wide variety of architectures, generally including controllable RES and operating either isolated or connected to the grid.

An illustrative example can be found in [13], where two optimization algorithms are developed, based on a Genetic Algorithm (GA) and MILP, respectively. Both algorithms are used in a radial low-voltage European microgrid for which the authors formulated a set of objective functions and constraints, attending to the different modes of operation of the microgrid, such as cost-efficiency, grid supporting, reliable isolated operation, eco-friendliness and multi-functional operations. The results demonstrate a better performance of the GA in comparison to MILP. Similarly, in [31], a more complex problem is formulated by considering start-up and shut-down costs associated to the distributed generators (DGs). This approach is used in a microgrid, being the problem addressed by means of a hybrid optimal algorithm, which consists in decomposing the problem into Integer Programming (IP) to solve the UC problem and Non-Linear Programming (NLP) to solve the ED problem. After that, both GA and interior-point algorithms are used to solve the IP and NLP problems, respectively. An Enhanced Genetic Algorithm (EGA) is proposed in [33] to address both the UC and ED problems simultaneously. The performance and effectiveness of the developed GA is verified in a set of case-study optimization scenarios, which are applied to a typical test microgrid. The simulation results demonstrate a good performance (in terms of computational time and robustness) of the optimizer

under grid-connected operation mode, in contrast with the isolated mode, where the computational resources required increase.

In [34], the minimization of the energy cost is assumed as the objective function for the optimization problem. The problem is addressed by applying an evolutionary approach based on Memory-Based Genetic Algorithm (MGA). The results are compared with two variants of Particle Swarm Optimization (PSO) algorithms, exhibiting a noticeably superior behavior. Similarly, the authors of [35] addressed the same problem by improving a GA with the integration of a Simulated Annealing (SA) algorithm to accelerate the convergence, demonstrating a clear advantage in convergence time.

In [36], the optimal size of the storage systems and the RE micro-sources is studied by means of a fuzzy multi-objective optimization model. The approach is based on a chaos optimization algorithm, which is introduced into a Binary particles Swarm Optimization (BPSO) algorithm, to propose a Chaotic BPSO (CBPSO). Furthermore, some authors proposed the use of Monte Carlo simulations as a tool to generate scenarios. In [37], the non-parametric neural network based prediction intervals (PIs) are implemented for forecast uncertainty quantification of wind power. A GA is then used to solve the Stochastic Unit Commitment (SUC) problem, being the Monte Carlo simulations used to create the scenarios. The simulation results demonstrate a better performance of the CBPSO in comparison with the original BPSO. Similarly, in [32], the uncertainty of demand and wind sources is considered, being modeled by means of absolute percentage error. Demand and wind power scenarios are generated using Monte Carlo simulations. To optimize the UC problem, the priority list method (PL algorithm) [38] is applied.

Table 1. Relevant literature in optimization of microgrids. Objective Function: Operation Cost (OC), Emission Cost (EC), Compensation Cost of Load Shedding (CCLS), network loss (NL), Economical Revenue (ER). Type: Single Objective. Microgrid: Standalone (SA), Grid Connected (GC). Approach: Deterministic Unit Commitment (DUC), Stochastic Unit Commitment (SUC). Strategy: Genetic Algorithm (GA), Enhanced Genetic Algorithm (EGA), Integer Programming (IP), Non-Linear Programming (NLP), Simulated Annealing (SA), Mixed Integer Linear Programming (MILP), Binary Particle Swarm Optimization (BPSO), Chaotic Binary Particle Swarm Optimization (CBPSO).

Ref.	Objective Function	Type	Microgrid	Approach	Strategy
[13]	min OC	SO	SA, GC	DUC	GA, MILP
[20]	min f(OC, EC, CCLS, NL)	SO	SA	DUC	BPSO
[31]	min OC	SO	GC	DUC	GA + IP (UC), NLP(ED)
[33]	min OC	SO	SA	DUC	EGA
[34]	min OC	SO	SA	DUC	MGA
[35]	min OC, max ER	SO	SA and GC	DUC	GA + SA
[36]	min EC, min NL	SO	SA	SUC	BPSO, CBPSO
[37]	min GC	SO	GC	DUC, SUC	GA
[32]	min GC, min SUC + SDC	SO	GC	SUC	PL

As steps forward with respect to the previous works, this paper proposes:

- Two main modes of operation are considered: cost effective operation mode, in which the main aim is to minimize the operation and maintenance cost of the overall system; and eco-mode operation mode, in which the objective is to reduce the polluted emissions of the dispatchable units.
- The general model improves the scheduling problem of microgrids by considering different levels of reliability according to the uncertainty of the forecast demand. Thus, the spinning reserve of dispatchable generation units guarantees that the variability of the demand is covered.

3. Problem Description

New types of generation technologies have emerged and have been gradually integrated into the existing power systems in the last decades [39], moving their classical architecture to distributed schemes. These technologies have associated lower emissions and lower operation costs than conventional generators. Examples of this type of technologies are micro-turbines, photo-voltaics and fuel cells, among others. Despite the positive features aforementioned, the application of these distributed architectures have many associated problems that must be deeply studied [40]. This challenge can be partially addressed by microgrids, which are entities that coordinate the Distributed Energy Resources (DER) in a consistently more decentralized way, thereby reducing the control burden on the grid and permitting them to provide their full benefits [41].

Under this new paradigm, a microgrid contains multiple generators that have a wide range of operation modes. Thus, several strategies can be applied to meet the required power demand, which varies from hour to hour over the day [12]. This problem is formally defined as the Unit Commitment (UC) and Economic Dispatch (ED) problems. The general objective of both is to minimize the total operating cost, while satisfying all of the constraints so that a given security level can be met [14,42,43]. The UC problem studies which generators must be in operation at certain time instant, while the ED studies, once the generators connected to the grid are known, the power that must be supplied by each of them.

These approaches attend to cover not only to economical factors, but it also considers environmental and technical limitations.

In particular in this paper, we consider the study of the microgrid depicted in Figure 1. This grid contains four generators, being two of them dispatchable generating units. Recall that a dispatchable generating unit refers to sources of electricity that can be used on demand at the request of operators, that is, can be turned on and off, or can adjust their power output according to the needs. Thus, the microgrid under study is composed by a diesel engine (DE) and a microturbine (MT) as dispatchable units, and a wind turbine (WT) and a photo-voltaic plant (PV) as non-controllable RES. Finally, an Energy Storage System (ESS) is also considered. The model of these components, together with the customer demands, is studied in the subsequent sections. Thus, the problem studied is to determine the power supplied by the different generators as well as the power supplied or demanded by the ESS at every time instant, minimizing certain cost function. This cost function attends to economical, technical, and environmental factors. It is relevant to note that this is a generic microgrid, being the proposed method equally valid to any other microgrid scheme.

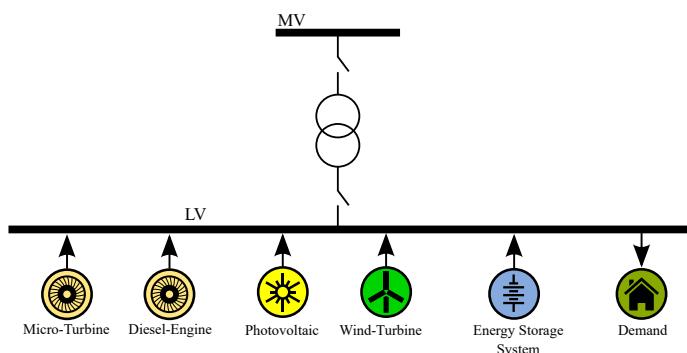


Figure 1. Structure of the microgrid considered.

4. System Modeling

The upcoming sections deal with the model taken into consideration for the generation schedule problem. All models presented in this section have been used widely, however, in practice, their accuracy can vary substantially. Nevertheless, since the paper presents a robust solution to the UC and ED problems, when uncertainties in the demand forecasting are considered, greater uncertainties can be established in order to take into account other model inaccuracies.

4.1. Demand Forecasting

One important issue that has a significant impact on the solution of the problem is the accuracy of the considered data. The energy demanded in the microgrid implies the effective utilization of the energy resources to ensure reliability level in the energy supply. Nevertheless, the demand in a microgrid is usually estimated based on the habits of the customers and data records. This demand forecasting can fall into inaccuracy when no information about the grid is known or new entities connect to the network.

In this paper, we consider an estimated curve of demand that is affected by a final error. This error is considered to follow a normal distribution at every time instant t , $\mathcal{N}(\mu_t, \sigma_t)$, whose average, μ_t , is considered zero and the standard deviation, σ_t , varies according to the level of reliability required to the problem resolution. In that way, if we consider a high value of σ_t , the uncertainty in the demand forecasting will be greater and a more robust solution must be contributed to guarantee the electrical supply under normal operation.

Let $\tilde{P}_{DM,t}$ and $P_{DM,t}$ be the estimation and the real power demanded from the microgrid at time t , respectively, and let $e_{DM,t}$ be the estimation error of the demand forecasting at time t . Thus, it is clear that

$$\tilde{P}_{DM,t} + e_{DM,t} = P_{DM,t}, \quad \forall t, \quad (1)$$

with $e_{DM,t} \sim \mathcal{N}(0, \sigma_t)$.

It is worth pointing out that, for the normal distribution $\mathcal{N}(\mu_t, \sigma_t)$, the values less than one standard deviation, σ_t , away from the mean, μ_t , account for 68.27% of the set, while two and three standard deviation away from the mean account for 95.45% and 99.73% of the set, respectively [44]. Thus, if the solution of the problem guarantees the supply of a power demanded $P_{DM,t} \in [\tilde{P}_{DM,t} - 3\sigma_t, \tilde{P}_{DM,t} + 3\sigma_t]$, then a reliable solution is achieved with a high confidence interval. To obtain a good estimation of the demand forecasting uncertainties, an ARMA (Auto Regressive Moving Average) model was trained with two years of estimation data.

4.2. Photo-Voltaic Generator

A PV generator consists of a set of PV panels connected among them that provide power to one or more solar inverters. These inverters transform the DC power received into AC power that is finally consumed in the grid. The power produced by a PV plant depends on many factors, such as the solar irradiation, the ambient and solar cell temperatures, and the modules degradation. Furthermore, the power generated by these kind of systems is directly related with the operational point of the solar modules. This operational point is fixed by the power inverter by using a Maximum Power Point Tracking (MPPT). In that way, the system will always operate supplying the maximum amount of power available in the resources.

In this paper, we consider the simplified model presented in [45] that is shown next:

$$P_{PV,t} = P_{STC} \frac{n \cdot E_{M,t}}{E_{STC}} [1 + k(T_{M,t} - T_{STC})], \quad \forall t, \quad (2)$$

where $P_{PV,t}$ is the output power of the PV plant at time t , $E_{M,t}$ is the solar irradiance at t and P_{STC} , E_{STC} and T_{STC} are the the maximum power, the irradiance and the temperature under Standard Test Conditions (STC), respectively. Those values correspond to a cell temperature of 25 °C and

an irradiance of 1000 W/m^2 with an air mass 1.5. Finally, n denotes the number of PV panels, k is the power temperature coefficient ($^{\circ}\text{C}$) and $T_{M,t}$ is the temperature of the module at time t , which can be calculated as $T_{M,t} = T_{amb} + \varepsilon_{PV} \frac{E_{M,T}}{E_{STC}}$, where T_{amb} is the ambient temperature ($^{\circ}\text{C}$) and ε_{PV} is a constant module provided by the manufacturer.

4.3. Wind Turbine

There exist many publications dealing with the modeling and simulation of wind turbines [46,47]. Most of these models have a great level of detail and are used below to perform stability analysis (see, for instance, [48]). For our study, we consider the sequel simplified model of the generator:

$$P_{WT,t} = \begin{cases} 0 & \text{for } v < v_{ci}, \\ P_r \frac{v^3 - v_{ci}^3}{v_r^3 - v_{ci}^3} & \text{for } v_{ci} < v < v_r, \\ P_r & \text{for } v_r < v < v_{co}, \\ 0 & \text{for } v > v_{co}, \end{cases} \quad \forall t, \quad (3)$$

where P_r and v_r represent the rated power (kW) and wind speed (m/s), respectively, and v_{ci} , v_{co} and v are the cut-in, cut-out and actual wind speed, respectively. For a more detailed information about the model, reader is referred to [49].

4.4. Diesel Engine

Nowadays, diesel engines are the most common type of microgrid generator technology in use. The operation cost of a power system can be expressed as a function of its real power output and it is usually modeled as a quadratic polynomial with the shape:

$$C_{DE,t} = d_{DE} + e_{DE}P_{DE,t} + f_{DE}P_{DE,t}^2, \quad \forall t, \quad (4)$$

where $C_{DE,t}$ is the total fuel cost (€/h) at time t , $P_{DE,t}$ is the power output at time t and d_{DE} (€/h), e_{DE} (€/kWh) and f_{DE} ($\text{€/kW}^2 \text{ h}$) are parameters specified by the manufacturer [50], and are strongly conditioned by the type of engine, generator and fuel. Additionally, let P_{DE}^{\min} and P_{DE}^{\max} be the minimum and maximum power that the DE can supply at every time instant. Then,

$$P_{DE}^{\min} \leq P_{DE,t} \leq P_{DE}^{\max}. \quad (5)$$

4.5. Microturbine

The MT model is similar to the DE model. Nevertheless, in this case, the operation cost curve parameters are adopted to model the performance and efficiency of a MT unit [51]. Thus, the operation cost can be expressed as:

$$C_{MT,t} = d_{MT} + e_{MT}P_{MT,t} + f_{MT}P_{MT,t}^2, \quad \forall t, \quad (6)$$

where $C_{MT,t}$ is the total gas cost (€/h) at time t , $P_{MT,t}$ is the power output at time t and d_{MT} (€/h), e_{MT} (€/Kw h) and f_{MT} ($\text{€/Kw}^2 \text{ h}$) are parameters specified by the manufacturer [50,51], and depend on the type of turbine, generator and gas. The operation cost curves of the DE and MT in function of the power given will be presented in subsequent sections. Analogously with the DE, the power generated by the MT is physically limited:

$$P_{MT}^{\min} \leq P_{MT,t} \leq P_{MT}^{\max}, \quad (7)$$

where P_{MT}^{\min} and P_{MT}^{\max} are the minimum and maximum power that the DE can supply at every time instant.

4.6. Spinning Reserve

The term spinning reserve is widely used in the literature [52,53]. Nevertheless, this service can be defined in different ways leading to confusion. We define this concept as it is done in [54]: the spinning reserve is the unused capacity that can be activated on decision of the system operator and is provided by devices, which are synchronized to the network and able to change the active power.

Note that this capacity is only found in the dispatchable units, as they are the only units that can be used on demand. Thus, we denote $R_{DE,t}$ and $R_{MT,t}$ the spinning reserve of the DE and the MT at time instant t , respectively. These parameters are mathematically defined next:

$$R_{DE,t} = P_{DE,t}^{max} - P_{DE,t}, \quad R_{MT,t} = P_{MT,t}^{max} - P_{MT,t}, \quad (8)$$

4.7. Energy Storage System

Batteries are electrochemical devices that store energy from other AC or DC sources for later use [51]. The battery allows the microgrid to cover demand peaks and to store excesses of generation due to its quick response. We consider a set of batteries that conforms an ESS. An ESS is particularized by three parameters:

1. The capacity is the amount of electric charge that the ESS can deliver at the rated voltage.
2. The maximum charge rate is a measure of the rate at which a battery can be charged.
3. The maximum discharge rate is a measure of the rate at which a battery can be discharged.

Let $P_{ESS,t}$ be the power demanded or supplied by the ESS at time t . Note that the value of $P_{ESS,t}$ can be both positive or negative. If $P_{ESS,t} > 0$, the ESS is supplying power to the microgrid, while, when $P_{ESS,t} < 0$, the ESS is charging and acting as a consumer. Attending to the charging/discharging rate, both parameters are bounded due to physical limitations:

$$P_{ESS,t} \leq P_{ESS}^{max}, \quad (9)$$

$$P_{ESS,t} \geq P_{ESS}^{min}. \quad (10)$$

Let SOC_t be the State of Charge of the ESS at every time t . According to the energy stored in the battery, the SOC_t will take different values. Two constraints must be taken into consideration when dealing with the state of charge of the ESS. The SOC_t must lay in a band bounded by the capacity of the battery and the minimum admissible state of charge. That is:

$$SOC^{min} \leq SOC_t \leq SOC^{max}, \quad \forall t, \quad (11)$$

where SOC^{min} and SOC^{max} are the lower and upper boundaries for the SOC_t . Additionally, it is important to point out that the battery is a dynamical system, that is, the state of charge of the ESS depends on the previous power flows through its terminals. Thus,

$$SOC_{t+1} = SOC_t - \begin{cases} P_{ESS,t} \Delta t \eta_c & \text{for } P_{ESS,t} < 0 \\ \frac{P_{ESS,t} \Delta t}{\eta_d} & \text{for } P_{ESS,t} > 0 \end{cases}, \quad \forall t, \quad (12)$$

where η_c and η_d are, respectively, the charging and discharging efficiency and Δt is the time between samples. Recall that, when $P_{ESS,t} > 0$ and ESS is discharging, the SOC_{t+1} decreases. Conversely, when $P_{ESS,t} < 0$ and ESS is charging, the SOC_{t+1} increases its value.

4.8. Power Balance

In contrast with other approaches to the same problem, similar to Nemati et al. [13], we consider an isolated microgrid, i.e., it lacks connection to the distribution network. This fact implies that the power demanded by the customers must be locally supplied by the distributed energy resources presented in the microgrid. Thus, the power balance must be fulfilled at every time interval t , that is

$$P_{DM,t} = P_{PV,t} + P_{WT,t} + P_{DE,t} + P_{MT,t} + P_{ESS,t}, \quad \forall t. \quad (13)$$

It is important to point out that, when considering uncertainties in the demand forecasting, the estimation error must be taken into account in the problem in order to guarantee the reliability of the solution provided. This reliability is met with the well-sizing of the spinning reserve. Thus, the following constraint must be added to the problem:

$$R_{DE,t} + R_{MT,t} \geq n_r \sigma_t, \quad (14)$$

where σ_t is the standard deviation of the estimation error and n_r is a scalar parameter that, once fixed, establishes the reliability degree of the solution adopted. A deeper study of this issue is presented in Section 5.3.

4.9. Other Operation Costs

In addition to all the costs aforementioned, the operation of the microgrid introduces extra costs associated to maintenance, start-up and emissions costs.

1. Maintenance cost: The operating and maintenance cost of each dispatchable generating unit is assumed to be proportional to the power production [51,55]:

$$C_{OM_{DE}} = k_{OM_{DE}} \sum_{\forall t} P_{DE,t} \Delta t, \quad \forall t, \quad (15)$$

$$C_{OM_{MT}} = k_{OM_{MT}} \sum_{\forall t} P_{MT,t} \Delta t, \quad \forall t, \quad (16)$$

where $K_{OM_{DE}}$ (€/kW h) and $K_{OM_{MT}}$ (€/kW h) are the maintenance costs of DE and MT, respectively.

2. Start-up cost: The generator start-up cost depends on the time at which the unit has been off prior to start up [56]. Thus, the start-up cost at any given time can be estimated as [57]:

$$C_{SU_{DE}} = a_{DE} + b_{DE} \left[1 - \exp \left(\frac{-T_{DE,OFF}}{c_{DE}} \right) \right], \quad (17)$$

$$C_{SU_{MT}} = a_{MT} + b_{MT} \left[1 - \exp \left(\frac{-T_{MT,OFF}}{c_{MT}} \right) \right], \quad (18)$$

where a_{DE} and a_{MT} (€) are the hot start-up costs, b_{DE} and b_{MT} (€) are the cold start-up costs, c_{DE} and c_{MT} (€) are the unit cooling time constant and $T_{DE,OFF}$ and $T_{MT,OFF}$ represent the time that each unit has been off (for a more detailed explanation about this expression, the reader is referred to [57]).

3. Emission costs: The cost of environmental externalities (production of pollutants CO₂, SO₂ or NO_x) is assumed to be a linear function of energy generation [13]:

$$CEM_{DE} = \sum_{k=1}^{Nem} \sum_{\forall t} \alpha_k \beta_{DE,k} P_{DE,t} \Delta t, \quad \forall t, \quad (19)$$

$$CEM_{MT} = \sum_{k=1}^{Nem} \sum_{\forall t} \alpha_k \beta_{MT,k} P_{MT,t} \Delta t, \quad \forall t, \quad (20)$$

where Nem is the number of emission types, α_k is externality costs of emission type k (€/kg), and $\beta_{DE,k}$ and $\beta_{MT,k}$ are the emission factors of the dispatchable generating units and the emission type k (kg/kWh).

5. Microgrid Operation Modes

As introduced in the previous sections, there exist a high number of limitations and cost parameters to take into consideration when scheduling the power generation in a microgrid. In this section, several operation modes are presented. In each of them, a certain operation criterion is followed to optimize a particular cost function.

5.1. Cost-Effective Operation Mode

This operation mode is focused on the reduction of the overall cost of the microgrid. Thus, the cost function considers the sequel parameters:

- cost of operation and maintenance of the dispatchable units (DE and MT);
- start-up costs of the dispatchable units (DE and MT); and
- fuel and gas costs of the DE and MT, respectively.

The cost function is mathematically defined as follows:

$$CF_{ec} = C_{OM_{DE}} + C_{OM_{MT}} + C_{SU_{DE}} + C_{SU_{MT}} + \sum_{\forall t} (C_{DE,t} + C_{MT,t}). \quad (21)$$

5.2. Eco-Mode Operation

In this operation mode, the main aim is to guarantee the electric supply in the microgrid, ensuring a minimization of the detrimental emissions that are the main cause of climate change. Climate change is expected to have unprecedented implications on where people can settle, grow food, build cities, and rely on functioning ecosystems for the services they provide. In many places, temperature changes and sea-level rise are already putting ecosystems under stress and affecting human well-being. This fact has induced many countries to set up policies to fight against climate change. At European level, a comprehensive package of policy measures to reduce greenhouse gas emissions has been initiated through the European Climate Change Program (ECCP).

Thus, based on the models defined in previous sections, the eco-cost function can be written as:

$$CF_{ef} = CEM_{DE} + CEM_{MT}, \quad (22)$$

where it is important to note that the rest of elements does not imply any cost.

5.3. Robust Operation Mode

As mentioned in Section 4, this paper considers uncertainties in the demand forecasting. This issue becomes a problem when trying to operate the microgrid in isolated mode, i.e., disconnected from the main grid. Thus, it is reasonable to consider a complementary mode of operation that guarantees the reliability of the studied microgrid.

The consideration of these uncertainties in the problem is what is nowadays known as Stochastic Unit Commitment (SUC) problem. This problem requires a more robust solution, which is able to deal with the uncertainties presented in the proposed formulation. In this paper, we consider that the estimation error of the demand forecasting follows a normal distribution with mean zero and standard deviation at time t , σ_t , as exposed in Section 4.1. The solution proposed consists in designing the spinning reserves of the dispatchable units in such a way that the reserve power can meet the demand estimation error for several levels of reliability according to the value of n_r introduced in Equation (14) (Figure 2 shows the reliability level for values of $n_r = 1$, $n_r = 2$ and $n_r = 3$).

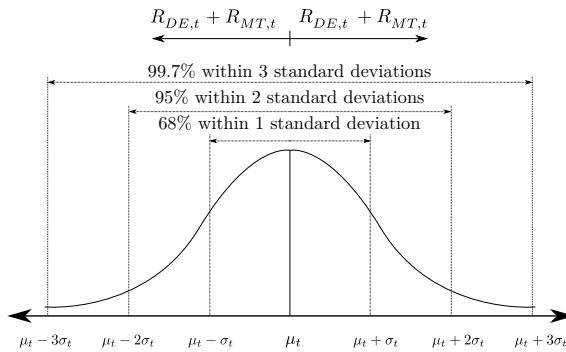


Figure 2. Normal distribution of the demand estimation error.

This mode of operation is complementary to the ones described above since it includes additional constraints to the problem, not changing the cost functions in Equations (21) and (22). In this mode, more expensive solutions are expected to be obtained, given the severe constraints related to robustness that they must fulfill.

6. Evolutionary Computational Approach

Genetic algorithms (GAs) are meta-heuristic algorithms that have been widely used for solving complex engineering problems [58,59]. GAs are based on the Darwinian theory of biological evolution. The basic idea is to have a set of potential solutions, called the population, which evolves over a number of generations by using genetic operators such as selection, crossover, and mutation [60]. The potential solutions encode in a chromosome-like structure the designing variables. This structure is called an individual and each designing variable represents a gene. In this work, the designing variables are the power supplied/consumed by MT, DE, and ESS since they are the elements of the considered microgrid that have higher impact on the operational cost of the microgrid (see Figure 1). RES, such as PV and WT, will always contribute to the demanded power as long as the solar and wind conditions are favorable, since their maintenance and operational costs can be neglected with respect to the DE and MT generators. Furthermore, since the power balance at each time instant should be fulfilled, whether the ESS supply or consume power at each time interval t , is determined by the power balance between the demand and the generation of the rest of elements of the microgrid.

6.1. Genetic Algorithm Implementation

There are many possible implementations of single-objective GAs [61]. In the proposed approach, a mupluslambda variant is used [62]. Algorithm 1 shows the implemented approach. The algorithm begins with a random initial population P_i , which is evaluated. It is important that the individuals that form the initial population are valid. This aspect is relevant in problems with multiple constraints as the one described in this paper (see Section 4). Then, offspring μ is created by using crossover and mutation operations. p_{cx} and p_{mut} refer to the crossover and mutation probabilities, respectively. Both p_{cx} and p_{mut} are hyper-parameters of the algorithm that should be selected carefully to guarantee a good converge of the GA. Next, the offspring is evaluated, and the new population λ is selected from the offspring generated and the previous population P_g . This approach guarantees a good level of elitism since parents and offspring compete each other to be selected for the next generation [62]. After completion, the algorithm returns the best individual obtained throughout the generations.

Algorithm 1: GA mupluslambda.

```

1 Create initial population  $P_i$ ;
2 Evaluate  $P_i$ ;
3  $P_g = P_i$ ;
4 while stop == False do
5   Parents' selection;
6   Create offspring  $\mu$  (crossover  $p_{cx}$  and mutation  $p_{mut}$ );
7   Evaluate  $\mu$  ;
8   Select new population  $\lambda$  ( $\mu + P_g$ );
9    $P_g = \lambda$ ;
10 end

```

6.1.1. Individual Representation

Each individual represents a list containing the power supplied by both MT and DE for a period of 24 h, using intervals of 1 h. Therefore, the size of each individual is 48 genes. It is worth recalling that the power supplied or consumed by the ESS can be derived from the power balance, and the renewable sources will always contribute to the demanded power as long as the climate conditions are suitable. Figure 3 shows the encoding used to represents the individuals of the GA.

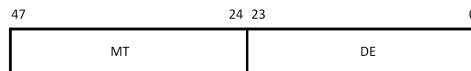


Figure 3. Individual representation.

6.1.2. Fitness Function

The fitness function used depends on the operation mode of the microgrid. Three operation modes have been defined in Section 5 that use a single-objective fitness function, such as cost-effective, eco-mode, and robust operation modes.

In the case of cost-effective mode, the objective function is defined as:

$$\begin{cases} \text{if solution valid } F = \text{Equation (21)}, \\ \text{else } F = \infty, \text{ according to Equations (5), (7), (9), (10), (11), (12), and (13).} \end{cases} \quad (23)$$

In the case of eco-mode, the objective function used is:

$$\begin{cases} \text{if solution valid } F = \text{Equation (22)}, \\ \text{else } F = \infty, \text{ according to Equations (5), (7), (8), (9), (10), (11), (12), and (13).} \end{cases} \quad (24)$$

In the case of robust mode, the fitness function used is:

$$\begin{cases} \text{if solution valid } F = \text{Equation (22)}, \\ \text{else } F = \infty, \text{ according to Equations (5), (7), (8), (9), (10), (11), (12), (13), and (14).} \end{cases} \quad (25)$$

It is important to highlight that, in the three fitness functions in Equations (23)–(25), the death penalty is used to penalize invalid solutions. Therefore, these invalid solutions do not participate in the genetic operations since they are not chosen by the selection scheme.

6.1.3. Genetic Operators

Tournament selection mechanism is used since it provides suitable results [61]. In each tournament, a number of individuals are randomly selected, which compete each other to be chosen

as a parent; the best one is then selected as one of the parents to be used in crossover and mutation operations [61]. A tournament size of three has been demonstrated to be suitable for the majority of problems. Regarding the crossover operation, two schemes have been evaluated: two-point and Simulated Binary Crossover (SBX) [63] methods. The two-point crossover consists of swapping the genetic information of two parents using two points as the indexes of the genetic exchange. SBX is a method to simulate one point crossover for continuous variables. An eta hyper-parameter is used to determine the similarity among selected parents and children. A high eta value will produce children resembling their parents, while a small eta value will produce much more different solutions. The mutation scheme used is a tailored Gaussian mutation algorithm, where each variable can change according to a Gaussian distribution with mean μ and standard deviation σ . The variability of a given gene after mutation depends on the value of σ .

7. Simulation Results

In this section the application of the proposed evolutionary approach is discussed. For this, a particularization of the microgrid presented in Section 3 is first presented, being the GA applied to three different case-studies. Lastly, the results are shown together with the values of the cost functions for the different operation modes. A simulation framework was developed in Python using DEAP library [64]. The simulator is available in [65].

7.1. Example scenario settings

The proposed example scenario consisted in solving the 24 h short-term operation scheduling of the microgrid introduced in Section 3. A sample time of 1 h was considered in all the simulations, however, the consideration of a shorter sampling is also possible. For this microgrid, two dispatchable units (DE and MT), two renewable resources (PV and WT) and an ESS were considered. The configuration parameters of each of the dispatchable generators together with their operation, start-up and maintenance costs coefficients are exposed in Table 2.

Table 2. Characteristic parameters of each of the generators considered in the microgrid.

i	P_i^{min} (kW)	P_i^{max} (kW)	d_i (€/h)	e_i (€/kWh)	f_i (€/kW ² h)
DE	5	80	1.9250	0.2455	0.0012
MT	20	140	7.4344	0.2015	0.0002
i	a_i (€)	b_i (€)	c_i (€)	K_{OMi} (€/kWh)	
DE	0.3	0.4	5.2	0.01258	
MT	0.4	0.28	7.1	0.00587	

Furthermore, Figure 4 depicts the operation costs of the dispatchable units. Notice that the DE generation is cheaper for power values under 55 kW. It is worth pointing out that the operation cost of DE is lower than MT when supplying low power. Nevertheless, DE is much more polluting than MT (see Table 3). Therefore, when the power given by the generator increases significantly, MT is the cheaper and lower-emissions solution. This fact makes cost the functions in Equations (21) and (22) have a minimum value in two different operation points.

In Figure 5, the start-up cost is depicted for both dispatchable units with respect to the time that the unit has been off. As can be observed, the cold start of MT has a higher cost than DE; nevertheless, after 5 h of not operation, MT is cheaper than reactivating.

The cost coefficients of Equations (19) and (20) are particularized for DE and MT in Table 3. We considered three emission types: CO₂, SO₂ and NO_x. The ESS parameters are defined in Table 4.

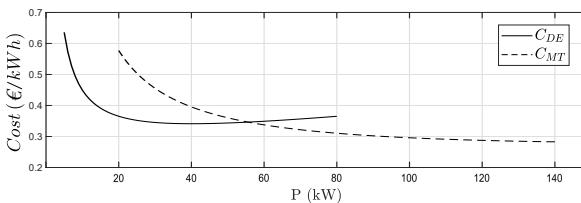


Figure 4. Cost of operation of the DE and MT in terms of the power supply.

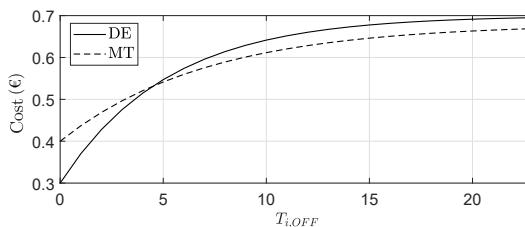


Figure 5. Start-up cost of the dispatchable units in terms of the time the unit has been off.

Table 3. Parameters of the externality costs and the emission factors of the main grid generation.

Emission Type	α_k	$\beta_{DE,k}$	$\beta_{MT,k}$
CO_2	0.0275	0.6495	0.7239
SO_2	1.9475	0.2059	0.0036
NO_x	8.2625	9.8883	0.1995

Table 4. ESS characteristic parameters.

SOC^{min} (kWh)	SOC^{max} (kWh)	P_{ESS}^{min} (kW)	P_{ESS}^{max} (kW)	η_c	η_d
70	280	-120	120	0.9	0.9

The power demanded and the renewable resources generation for the short 24 h period considered are known in the problem. These curves are shown in Figure 6. The problem was solved considering one datum per hour. It is important to highlight that this time can be reduced, implying the increment of the number of variables of the problem, but preserving the problem formulation made in this work.

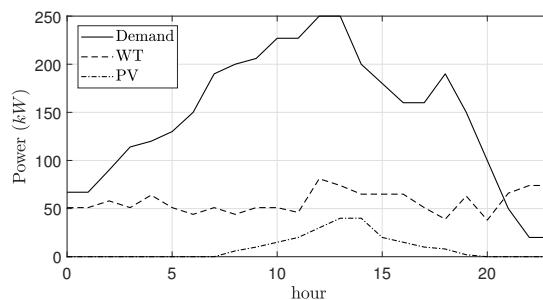


Figure 6. Power demanded and generated with renewable resources.

7.2. Genetic Algorithm Settings

The design of the generation schedule of the microgrid was addressed by means of a GA, using the selection, crossover and mutation rules proposed in Section 6. Table 5 contains the main configuration parameters of the GA implementation. It can be noticed that the proposed GA qA tested under different configuration parameters in terms of crossover and mutation probabilities. In addition, for the SBX method, a detailed evaluation of the influence of the eta hyper-parameter Qa carried out.

Table 5. Parameters of the GA.

Parameter	Value
λ	3000
μ	3000
Individuals (multi-objective)	3000
Generations	1000
Selection	Tournament size = 3
Crossover	Two-point scheme and Binary Simulated $p_{cx} = [0.6, 0.7, 0.8]$.
Mutation	Gaussian $p_m = [0.4, 0.3, 0.2]$, $\sigma = 30$.
Number of trials	30.

To show the convergence of the proposed GA, Figure 7 depicts the evolution of the individuals throughout the considered number of generations. It is shown that 1000 generations sufficed to guarantee convergence. Notice that the convergence of the algorithm could be affected by the value of σ used in the mutation algorithm. Similar convergence degrees were obtained for the rest of case-studies with the same value of σ .

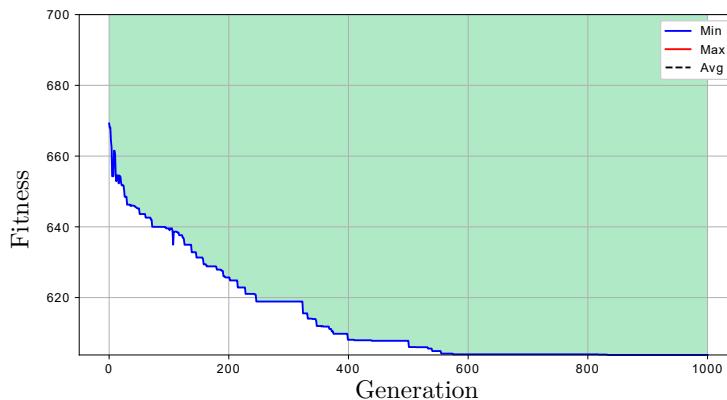


Figure 7. Evolution of the proposed GA, Case Study 1, two-point crossover, $p_c = 0.6$ and $p_m = 0.4$.

7.3. Results for the Case Studies

For this problem, three different scenarios are proposed, being the results listed below for each of them.

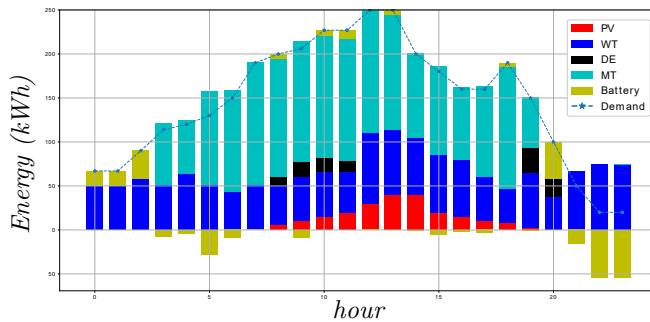
7.3.1. Results for Case-Study 1: Cost-Effective Operation Mode

This case study considered the resolution of the problem by minimizing the cost function in Equation (21). The best solutions obtained using the GA for this case-study are listed in Table 6. In addition, in Figure 8, the best solution for the microgrid schedule is represented.

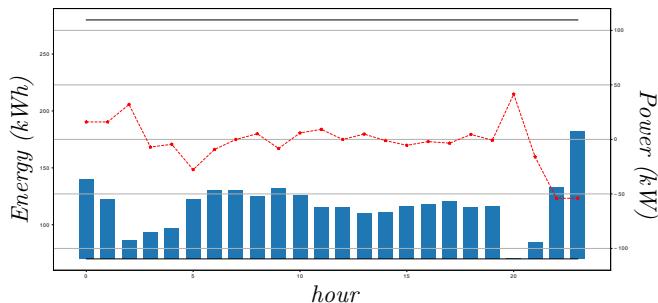
Table 6. Case-study 1 results, expressed in €.

	SBX			Two-Points						
P_{cx}	0.6	0.7	0.8	P_{mut}	0.6	0.7	P_{mut}	0.6	0.7	0.8
P_{mut}	0.4	0.3	0.2	eta	0.4	0.3	0.2	0.4	0.3	0.2
best(CF_{ec})	592.637	595.718	594.888		593.630	594.013	592.637	595.173	597.070	595.863
mean(CF_{ec})	602.995	603.793	606.089		603.370	604.439	606.066	603.146	604.071	605.758
$\sigma(CF_{ec})$	5.725	3.769	5.930		4.884	4.065	6.863	4.513	4.553	6.237
P_{cx}	0.6	0.7	0.8	P_{mut}	0.6	0.7	0.8			
P_{mut}	0.4	0.3	0.2	eta	0.4	0.3	0.2			
best(CF_{ec})	594.390	596.204	596.737		596.543	594.180	597.118			
mean(CF_{ec})	604.762	604.467	608.589		605.210	604.773	609.207			
$\sigma(CF_{ec})$	6.793	4.449	6.823		6.040	6.059	6.217			

Observing Table 6, it can be seen that the proposed approach led to very similar solutions, reaching the best one under the SBX scheme with $P_{cx} = 0.6$, $P_{mut} = 0.4$ and $eta = 0.1$. Analyzing Figure 8, it can be seen that MT, when it was connected to the microgrid, generated high amounts of power, which is in accordance with the operation costs shown in Figure 4. Analogously, DE always provides low power when connected, reducing in that way the operational costs.

**Figure 8.** UC and ED solution for Case Study 1.

Finally, Figure 9 shows the evolution of the SOC and the power supplied or demanded by the ESS.

**Figure 9.** Battery management for Case Study 1 where the bars are the SOC at every time instant and the red dashed line is the power given or required by the battery.

7.3.2. Results for Case-Study 2: Eco-Mode Operation Mode

This case study considered the resolution of the problem by minimizing the cost function in Equation (22). The best solution is depicted in Figure 10.

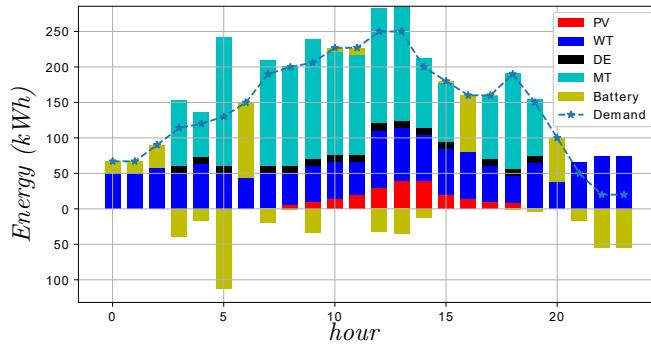


Figure 10. UC and ED solution for Case Study 2.

Different schemes were used to solve the GA problem. Table 7 shows the best solutions obtained. Note that this time the solution given by the SBX method with $P_{cx} = 0.7$, $P_{mut} = 0.3$ and $eta = 0.01$ was clearly better than the others. Furthermore, analyzing Figure 10, it can be seen that the DE generated less power in contrast with Case Study 1. This fact is a consequence of the high level of emissions produced by DE, as exposed in Table 3. Additionally, the EES was managed to disconnect the dispatchable units from the network at Hour 6, thus reducing the emissions in the microgrid.

Table 7. Case-study 2 results.

SBX					
P_{cx}	0.6	0.7	0.8	0.6	0.7
P_{mut}	0.4	0.3	0.2	0.4	0.3
eta	0.01			0.1	
$best(CF_{ec})$	15,577.973	15,511.697	17,043.111	15,525.373	16,279.030
$mean(CF_{ec})$	17,586.300	17,597.337	18,034.655	17,386.520	17,593.823
$\sigma(CF_{ec})$	775.725	954.216	771.705	714.173	635.349
P_{cx}	0.6	0.7	0.8	0.6	0.7
P_{mut}	0.4	0.3	0.2	0.4	0.3
eta	1			10	
$best(CF_{ec})$	16,359.787	16,395.022	17,095.309	15,580.220	16,470.354
$mean(CF_{ec})$	17,517.452	17,948.340	17,925.474	17,535.896	17,857.965
$\sigma(CF_{ec})$	805.524	694.802	524.494	765.017	662.151
Two-Points					
P_{cx}	0.6	0.7	0.8		
P_{mut}	0.4	0.3	0.2		
$best(CF_{ec})$	16,107.14	17,904.88	18,972.78		
$mean(CF_{ec})$	19,070.07	19,878.66	20,204.18		
$\sigma(CF_{ec})$	884.53	889.12	765.06		

Figure 11 depicts the evolution of the SOC and the power supplied or demanded by the ESS. Note that, in this operation mode, the ES was used to reduce the power generated by the dispatchable units, unlike the cost-effective operation mode, whose aim was to minimize the cost of generation of the power units.

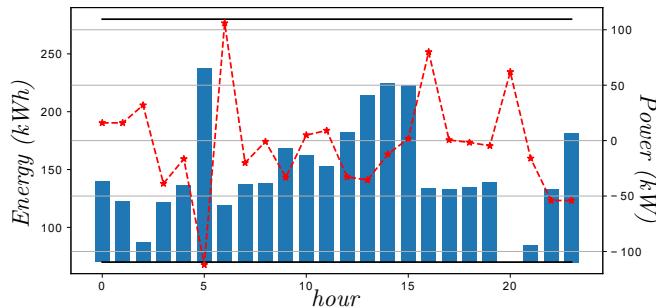


Figure 11. Battery management for Case Study 2 where the bars are the SOC at every time instant and the red dashed line is the power given or required by the battery.

7.3.3. Results for Case-Study 3: Robust Operation Mode

In this operation mode, an $n_r = 3$ level of reliability was guaranteed. That is, the isolated operation of the microgrid was guaranteed in 99.7% of scenarios. The objective of the problem was the same as in the cost-effective operation mode, i.e. minimize the total operation and maintenance cost in the microgrid.

Table 8 shows the results of the GA for this case study. Note that, in contrast with Case Study 1, the fitness function took higher values. This fact is a consequence of the reserve power, which must cover the possible deviation in the demand forecasting. As can be seen, the best solution was obtained for two-points, when the probabilities of crossover and mutation were, respectively, 0.8 and 0.2.

Table 8. Case-study 3 results.

	SBX			Two-Points		
P_{cx}	0.6	0.7	0.8	0.6	0.7	0.8
P_{mut}	0.4	0.3	0.2	0.4	0.3	0.2
η_{ta}	0.01			0.1		-
$best(CF_{ec})$	610.804	613.942	615.287	612.770	611.888	612.615
$mean(CF_{ec})$	619.718	622.898	623.017	621.496	623.111	623.970
$\sigma(CF_{ec})$	4.017	4.198	5.130	4.921	4.604	5.563
P_{cx}	0.6	0.7	0.8	0.6	0.7	0.8
P_{mut}	0.4	0.3	0.2	0.4	0.3	0.2
η_{ta}	1			10		
$best(CF_{ec})$	613.722	613.636	615.364	613.483	614.783	617.842
$mean(CF_{ec})$	621.852	625.127	625.648	621.520	624.422	627.119
$\sigma(CF_{ec})$	4.399	5.210	5.573	5.122	5.773	6.373

Figures 12 and 13 show the generation schedule and the battery management for the predicted scenario, i.e., considering the possible uncertainties in the demand estimation. It is worth pointing out that, in this case, the battery allowed reducing the amount of energy provided by MT at every time step, increasing in this way the spinning reserve of the microgrid.

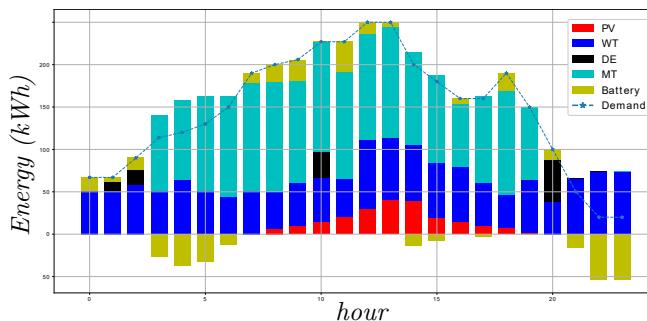


Figure 12. UC and ED solution for Case Study 3.

Finally, it is worth pointing out that the optimal solution in Case Study 2 (eco-mode operation mode) provided a value of 626.464 when it was evaluated by the cost function in Equation (21). Note that this value is not too far from the minimum. However, when replicating the same procedure with the optimal solutions for Case Studies 1 and 3 and evaluating by the cost function in Equation (22), it took the values of 4800.166 and 7518.955, respectively, which are very far from the optimum.

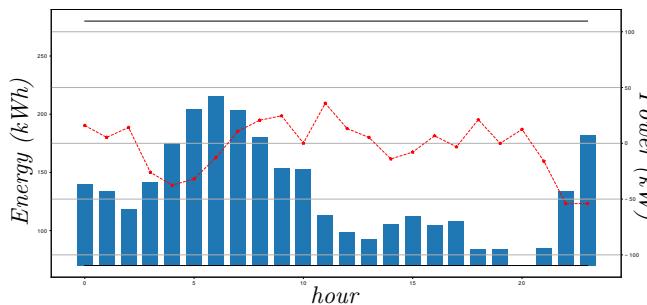


Figure 13. Battery management for Case Study 3 where the bars are the SOC at every time instant and the red dashed line is the power given or required by the battery.

8. Conclusions and Further Work

The present study was carried out for developing a GA to address the problem of finding the most suitable solution for the UC and ED problems in a microgrid. Based on the results, several conclusions can be formulated.

First, a detailed model of a microgrid was introduced to propose three case-studies (operation modes), which were addressed to validate the benefits of the GA to solve the combined problem of UC and ED. When the cost-effective operation mode was considered, the solution prioritized the use of DE instead of MT for low values of demanded power. However, when MT must be employed, it generated high amounts of power to have an appropriate power/cost ratio. With respect to the eco-mode operation mode, the microgrid minimized the use of DE due to its high levels of emissions, which are proportional to the power generated. In addition, the management of the battery system in both cases worked to reach the corresponding objectives, being an element of relevant importance to achieve this aim.

Regarding the limitations of the present work, the computational time required by the GA makes it low efficient to addressing the problem in real-time. In addition, despite the goodness of the obtained

results, the absence of guarantee of finding global solutions must always be taken into account, as the algorithm might converge at local minimum. For this reason, an appropriate tuning of the GA parameters is necessary when modifying the problem scenario. In future works, the results of the proposed evolutionary approach will be compared with other metaheuristic algorithms such as Particle Swarm Optimization (PSO) and Evolutionary Strategies (ES), among other techniques.

Considering the benefits of the proposed approach, several improvements are proposed as a further work. First, to increase the reliability of the results, a more sophisticated model of the ESS that considers the effects of battery degradation must be considered. In this same line of improvement, the implementation of an electricity price short-term forecasting is also proposed to develop a prize-based UC. Finally, the study of this optimization problem in a multi-objective mode is considered as further work. A multi-objective approach would provide a better understanding of the problem.

Author Contributions: Conceptualization, L.A.-B., A.R.d.N., A.T., J.L.M.-R., D.G.R.; Validation, A.R.d.N., A.T., D.G.R.; Writing original-draft, L.A.-B., A.R.d.N., A.T.; Writing-review and editing, J.L.M.-R., D.G.R.

Funding: Research partially supported by grant TEC2016-80242-P funded by AEI/FEDER through the Laboratorio de Simulación Hardware-in-the-loop de Sistemas Ciberfísicos (LaSSIC), the Spanish Ministry of Economy and Competitiveness under grant PCIN-2015-043 and the University of Seville under the contract “Contratos de acceso al Sistema Español de Ciencia, Tecnología e Innovación para el desarrollo del programa propio de I+D+i de la Universidad de Sevilla”

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Malik, F.H.; Lehtonen, M. A review: Agents in smart grids. *Electr. Power Syst. Res.* **2016**, *131*, 71–79. [[CrossRef](#)]
2. Kakran, S.; Chanana, S. Smart operations of smart grids integrated with distributed generation: A review. *Renew. Sustain. Energy Rev.* **2018**, *81*, 524–535. [[CrossRef](#)]
3. Bullrich-Massagué, E.; Díaz-González, F.; Aragüés-Peñaiba, M.; Girbau-Llistuella, F.; Olivella-Rosell, P.; Sumper, A. Microgrid clustering architectures. *Appl. Energy* **2018**, *212*, 340–361. [[CrossRef](#)]
4. Soshinskaya, M.; Crijns-Graus, W.H.; Guerrero, J.M.; Vasquez, J.C. Microgrids: Experiences, barriers and success factors. *Renew. Sustain. Energy Rev.* **2014**, *40*, 659–672. [[CrossRef](#)]
5. Ravichandran, A.; Malysz, P.; Sirospour, S.; Emadi, A. The critical role of microgrids in transition to a smarter grid: A technical review. In Proceedings of the 2013 IEEE Transportation Electrification Conference and Expo (ITEC), Detroit, MI, USA, 16–19 June 2013; pp. 1–7.
6. Kheradmand-Khanekhdani, H.; Gitizadeh, M. Well-being analysis of distribution network in the presence of electric vehicles. *Energy* **2018**, *155*, 610–619. [[CrossRef](#)]
7. Parhizi, S.; Lotfi, H.; Khodaei, A.; Bahramirad, S. State of the Art in Research on Microgrids: A Review. *IEEE Access* **2015**, *3*, 890–925. [[CrossRef](#)]
8. Feng, W.; Jin, M.; Liu, X.; Bao, Y.; Marnay, C.; Yao, C.; Yu, J. A review of microgrid development in the United States—A decade of progress on policies, demonstrations, controls, and software tools. *Appl. Energy* **2018**, *228*, 1656–1668. [[CrossRef](#)]
9. Hatziyargyriou, N.D.; Kleftakis, V.A.; Papadimitriou, C.N.; Messinis, G.M. Microgrids in Distribution. In *Smart Grid Handarticle*; Wiley Online Library: Hoboken, NJ, USA, 2016; pp. 1–24.
10. Zia, M.F.; Elbouchikhi, E.; Benbouzid, M. Microgrids energy management systems: A critical review on methods, solutions, and prospects. *Appl. Energy* **2018**, *222*, 1033–1055. [[CrossRef](#)]
11. Elsayed, W.; Hegazy, Y.; Bendary, F.; El-Bages, M. Energy management of residential microgrids using random drift particle swarm optimization. In Proceedings of the 2018 19th IEEE Mediterranean Electrotechnical Conference (MELECON), Marrakech, Morocco, 2–7 May 2018; pp. 166–171.
12. Padhy, N.P. Unit commitment—A bibliographical survey. *IEEE Trans. Power Syst.* **2004**, *19*, 1196–1205. [[CrossRef](#)]

13. Nemati, M.; Braun, M.; Tenbohlen, S. Optimization of unit commitment and economic dispatch in microgrids based on genetic algorithm and mixed integer linear programming. *Appl. Energy* **2018**, *210*, 944–963. [[CrossRef](#)]
14. Lei, X.; Lerch, E.; Xie, C. Frequency security constrained short-term unit commitment. *Electr. Power Syst. Res.* **2002**, *60*, 193–200. [[CrossRef](#)]
15. Blanco, I.; Morales, J.M. An efficient robust solution to the two-stage stochastic unit commitment problem. *IEEE Trans. Power Syst.* **2017**, *32*, 4477–4488. [[CrossRef](#)]
16. Wang, Q.; Wang, J.; Guan, Y. Stochastic unit commitment with uncertain demand response. *IEEE Trans. Power Syst.* **2013**, *28*, 562–563. [[CrossRef](#)]
17. Marneris, I.G.; Biskas, P.N.; Bakirtzis, A.G. Stochastic and deterministic unit commitment considering uncertainty and variability reserves for high renewable integration. *Energies* **2017**, *10*, 140. [[CrossRef](#)]
18. Khan, A.A.; Naeem, M.; Iqbal, M.; Qaisar, S.; Anpalagan, A. A compendium of optimization objectives, constraints, tools and algorithms for energy management in microgrids. *Renew. Sustain. Energy Rev.* **2016**, *58*, 1664–1683. [[CrossRef](#)]
19. Reddy, S.; Panwar, L.K.; Panigrahi, B.; Kumar, R.; Alsumaiti, A. Binary grey wolf optimizer models for profit based unit commitment of price-taking GENCO in electricity market. *Swarm Evolut. Comput.* **2019**, *44*, 957–971. [[CrossRef](#)]
20. Li, P.; Xu, D. Optimal operation of microgrid based on improved binary particle swarm optimization algorithm with double-structure coding. In Proceedings of the 2014 International Conference on Power System Technology, Chengdu, China, 20–22 October 2014; pp. 3141–3146.
21. Bendotti, P.; Fouilhoux, P.; Rottner, C. On the complexity of the unit commitment problem. *Am. Oper. Res.* **2019**, *274*, 119–130. [[CrossRef](#)]
22. Che, P.; Shi, G. An MILP approach for a profit-based unit commitment problem with emissions penalty. In Proceedings of the 26th Chinese Control and Decision Conference (2014 CCDC), Changsha, China, 31 May to 2 June 2014; pp. 4474–4477.
23. Zaree, N.; Vahidinasab, V. An MILP formulation for centralized energy management strategy of microgrids. In Proceedings of the 2016 Smart Grids Conference (SGC), Austin, TX, USA, 1–3 July 2016; pp. 1–8.
24. Zhang, D.; Liu, S.; Papageorgiou, L.G. Fair cost distribution among smart homes with microgrid. *Energy Convers. Manag.* **2014**, *80*, 498–508. [[CrossRef](#)]
25. Wang, M.Q.; Gooi, H. Spinning reserve estimation in microgrids. *IEEE Trans. Power Syst.* **2011**, *26*, 1164–1174. [[CrossRef](#)]
26. Marquant, J.F.; Evans, R.; Bollinger, L.A.; Carmeliet, J. A holarchic approach for multi-scale distributed energy system optimisation. *Appl. Energy* **2017**, *208*, 935–953. [[CrossRef](#)]
27. Fu, B.; Ouyang, C.; Li, C.; Wang, J.; Gul, E. An Improved Mixed Integer Linear Programming Approach Based on Symmetry Diminishing for Unit Commitment of Hybrid Power System. *Energies* **2019**, *12*, 833. [[CrossRef](#)]
28. Cupelli, L.; Schumacher, M.; Monti, A.; Mueller, D.; De Tommasi, L.; Kouramas, K. Simulation Tools and Optimization Algorithms for Efficient Energy Management in Neighborhoods. In *Energy Positive Neighborhoods and Smart Energy Districts*; Elsevier: Amsterdam, The Netherlands, 2017; pp. 57–100.
29. Guan, X.; Xu, Z.; Jia, Q.S. Energy-efficient buildings facilitated by microgrid. *IEEE Trans. Smart Grid* **2010**, *1*, 243–252. [[CrossRef](#)]
30. Wang, N.; Zhang, L.; Xie, G. An improved mixed integer quadratic programming algorithm for unit commitment. *Dianli Xitong Zidonghua (Autom. Electr. Power Syst.)* **2010**, *34*, 28–32. [[CrossRef](#)]
31. Li, H.; Zang, C.; Zeng, P.; Yu, H.; Li, Z. A genetic algorithm-based hybrid optimization approach for microgrid energy management. In Proceedings of the 2015 IEEE International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), Shenyang, China, 8–12 June 2015; pp. 1474–1478.
32. Jo, K.H.; Kim, M.K. Stochastic Unit Commitment Based on Multi-Scenario Tree Method Considering Uncertainty. *Energies* **2018**, *11*, 740. [[CrossRef](#)]
33. Nemati, M.; Bennimar, K.; Tenbohlen, S.; Tao, L.; Mueller, H.; Braun, M. Optimization of microgrids short term operation based on an enhanced genetic algorithm. In Proceedings of the 2015 IEEE Eindhoven PowerTech, Eindhoven, The Netherlands, 29 June–2 July 2015; pp. 1–6.

34. Askarzadeh, A. A memory-based genetic algorithm for optimization of power generation in a microgrid. *IEEE Trans. Sustain. Energy* **2018**, *9*, 1081–1089. [[CrossRef](#)]
35. Liang, H.; Gooi, H. Unit commitment in microgrids by improved genetic algorithm. In Proceedings of the 2010 Conference Proceedings IPEC, Singapore, 27–29 October 2010; pp. 842–847.
36. Li, P.; Xu, D.; Zhou, Z.; Lee, W.J.; Zhao, B. Stochastic Optimal Operation of Microgrid Based on Chaotic Binary Particle Swarm Optimization. *IEEE Trans. Smart Grid* **2016**, *7*, 66–73. [[CrossRef](#)]
37. Quan, H.; Srinivasan, D.; Khosravi, A. Incorporating wind power forecast uncertainties into stochastic unit commitment using neural network-based prediction intervals. *IEEE Trans. Neural Netw. Learn. Syst.* **2015**, *26*, 2123–2135. [[CrossRef](#)]
38. Ma, H.; Wang, B.; Gao, W.; Liu, D.; Sun, Y.; Liu, Z. Optimal Scheduling of an Regional Integrated Energy System with Energy Storage Systems for Service Regulation. *Energies* **2018**, *11*, 195. [[CrossRef](#)]
39. Ruth, M.F.; Kroposki, B. Energy systems integration: An evolving energy paradigm. *Electr. J.* **2014**, *27*, 36–47. [[CrossRef](#)]
40. Lasseter, R.H.; Paigi, P. Microgrid: A conceptual solution. In Proceedings of the 2004 IEEE 35th Annual Power Electronics Specialists Conference (IEEE Cat. No.04CH37551), Aachen, Germany, 20–25 June 2004; Volume 6, pp. 4285–4290. [[CrossRef](#)]
41. Hatziyargyriou, N.; Asano, H.; Iravani, R.; Marnay, C. Microgrids. *IEEE Power Energy Mag.* **2007**, *5*, 78–94. [[CrossRef](#)]
42. Shaw, J.J. A direct method for security-constrained unit commitment. *IEEE Trans. Power Syst.* **1995**, *10*, 1329–1342. [[CrossRef](#)]
43. Fotuhi-Firuzabad, M.; Billinton, R. Unit commitment health analysis in composite generation and transmission systems considering stand-by units. *IEE Proc. Gener. Transm. Distrib.* **1999**, *146*, 164–168. [[CrossRef](#)]
44. Patel, J.K.; Read, C.B. *Handbook of the Normal Distribution*; CRC Press: Boca Raton, FL, USA, 1996; Volume 150.
45. Lasnier, F.; Ang, T.G. *Photovoltaic Engineering Handarticle*; IOP Publishing: Bristol, UK, 1990.
46. Tapia, A.; Tapia, G.; Ostolaza, J.X.; Saenz, J.R. Modeling and control of a wind turbine driven doubly fed induction generator. *IEEE Trans. Energy Convers.* **2003**, *18*, 194–204. [[CrossRef](#)]
47. Lei, Y.; Mullane, A.; Lightbody, G.; Yacamini, R. Modeling of the wind turbine with a doubly fed induction generator for grid integration studies. *IEEE Trans. Energy Convers.* **2006**, *21*, 257–264. [[CrossRef](#)]
48. Miller, N.W.; Sanchez-Gasca, J.J.; Price, W.W.; Delmerico, R.W. Dynamic modeling of GE 1.5 and 3.6 MW wind turbine-generators for stability simulations. In Proceedings of the 2003 IEEE Power Engineering Society General Meeting (IEEE Cat. No.03CH37491), Toronto, ON, Canada, 13–17 July 2003; Volume 3, pp. 1977–1983.
49. Deshmukh, M.; Deshmukh, S. Modeling of hybrid renewable energy systems. *Renew. Sustain. Energy Rev.* **2008**, *12*, 235–249. [[CrossRef](#)]
50. Mohamed, F.A.; Koivo, H.N. System modelling and online optimal management of MicroGrid using Mesh Adaptive Direct Search. *Int. J. Electr. Power Energy Syst.* **2010**, *32*, 398–407. [[CrossRef](#)]
51. Mohamed, F.A.; Koivo, H.N. Online Management of MicroGrid with Battery Storage Using Multiobjective Optimization. In Proceedings of the 2007 International Conference on Power Engineering, Energy and Electrical Drives, Setubal, Portugal, 12–14 April 2007; pp. 231–236. [[CrossRef](#)]
52. Ortega-Vazquez, M.A.; Kirschen, D.S. Estimating the spinning reserve requirements in systems with significant wind power generation penetration. *IEEE Trans. Power Syst.* **2009**, *24*, 114–124. [[CrossRef](#)]
53. Ortega-Vazquez, M.A.; Kirschen, D.S. Optimizing the spinning reserve requirements using a cost/benefit analysis. *IEEE Trans. Power Syst.* **2007**, *22*, 24–33. [[CrossRef](#)]
54. Rebours, Y.; Kirschen, D. What is spinning reserve. *Univ. Manch.* **2005**, *174*, 175.
55. Azmy, A.; Erlich, I. Online optimal management of PEM fuel cells using neural networks. In Proceedings of the IEEE Power Engineering Society General Meeting, San Francisco, CA, USA, 16 June 2005; Volume 2, p. 1337. [[CrossRef](#)]
56. Otero, S.; Irving, M. Large scale unit commitment using a hybrid genetic algorithm. *Int. J. Electr. Power Energy Syst.* **1997**, *19*, 45–55. [[CrossRef](#)]
57. Wood, A.J.; Wollenberg, B.F. *Power Generation, Operation and Control*; Wiley Online Library: Hoboken, NJ, USA, 1984.

58. Arzamendia, M.; Gregor, D.; Reina, D.G.; Toral, S.L. An evolutionary approach to constrained path planning of an autonomous surface vehicle for maximizing the covered area of Ypacarai Lake. *Soft Comput.* **2019**, *23*, 1723–1734. [[CrossRef](#)]
59. Gutiérrez-Reina, D.; Sharma, V.; You, I.; Toral, S. Dissimilarity Metric Based on Local Neighboring Information and Genetic Programming for Data Dissemination in Vehicular Ad Hoc Networks (VANETs). *Sensors* **2018**, *18*, 2320. [[CrossRef](#)] [[PubMed](#)]
60. Holland, J.H. *Genetic Algorithms and Adaptation*; Springer: New York, NY, USA, 1984; pp. 317–333. [[CrossRef](#)]
61. Luke, S. *Essentials of Metaheuristics*, 1st ed.; lulu.com: 2009. Available online: [http://cs.gmu.edu/~sim\\$sean/books/metaheuristics/](http://cs.gmu.edu/~sim$sean/books/metaheuristics/) (accessed on 1 May 2019).
62. Ter-Sarkisov, A.; Marsland, S. Convergence Properties of Two ($\mu+\lambda$) Evolutionary Algorithms On OneMax and Royal Roads Test Functions. *arXiv* **2011**, arXiv:1108.4080.
63. Deb, K.; Agrawal, R.B. Simulated Binary Crossover for Continuous Search Space. *Complex Syst.* **1995**, *9*, 115–148.
64. Fortin, F.A.; De Rainville, F.M.; Gardner, M.A.; Parizeau, M.; Gagné, C. DEAP: Evolutionary Algorithms Made Easy. *J. Mach. Learn. Res.* **2012**, *13*, 2171–2175.
65. Reina, D. G. Evolutionary Microgrid. 2019. Available online: <https://github.com/Dany503/Evolutionary-Microgrids> (accessed on 1 May 2019).



© 2019 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

1.3 2018 International Conference on Smart Energy Systems and Technologies, (SEST 2018)

Stochastic Unit Commitment in Microgrids based on Model Predictive Control

Lázaro Alvarado Barrios
*Dept. of Engineering
Universidad Loyola Andalucía
Seville, Spain
lalvarado@uloyola.es*

Juan Boza Valerino
*Dept. of Electrical Engineering
Universidad de Sevilla
Seville, Spain
jbozavalerino@gmail.com*

Álvaro Rodríguez del Nozal
*Dept. of Engineering
Universidad Loyola Andalucía
Seville, Spain
arodriguez@uloyola.es*

Juan Manuel Escaño
*Dept. of Engineering
Universidad Loyola Andalucía
Seville, Spain
jmescano@uloyola.es*

José L. Martínez-Ramos
*Dept. of Electrical Engineering
Universidad de Sevilla
Seville, Spain
camel@us.es*

Francisco Gonzalez-Longatt
*School of Electronic, Electrical
and Systems Engineering
Loughborough University
Loughborough, United Kingdom
fglongatt@fglelongatt.org*

Abstract—This article deals with the problem of Stochastic Unit Commitment (SUC), considering the stochastic nature of demand and meteorological phenomena. This paper shows the optimal operation of a hybrid microgrid composed of the following generation units: wind turbine (WT), photovoltaic solar panel (PV), diesel engine generator (DE), micro-turbine (MT), as well as storage devices such as Battery Energy Storage (BES), considering its constraints and the requirements of the reserve generation. For this purpose, a Model-based Predictive Control (MPC), which uses dynamic models of prediction of renewable power and demand in real time, is developed, allowing feedback at each step of time, which corrects the uncertainty of the models. A comparison with a classic UC formulation has been made. The results reach a lower cost solution.

Index Terms—Stochastic Unit Commitment, Model Predictive Control, Microgrid.

I. INTRODUCTION

A microgrid is a bidirectional electric power system that allows the distribution of electricity from suppliers to consumers, favouring the integration of renewable generation sources. It is composed of interconnected loads, conventional (dispatchable) distributed renewable energy generation units and energy storage sources that operate in coordination to supply electricity at the distribution level [1]. It can operate interconnected to the general electrical grid, through one or several Point of Common Coupling (PCC) or it can operate isolated from the grid [2]. A microgrid can generate, store, control and manage part of the energy consumed, allowing the end user not only to be a consumer but also an active part of the grid [3].

Operating in parallel with the main grid, a microgrid can be operated as a single load or aggregate generator and could

work as an energy source integrated into the grid or as a way to provide ancillary services that would contribute to the stability and control of the main network [4]. In isolated mode, generators have to be able to respond quickly to changes in consumption so that voltage and frequency remain within acceptable limits. [5].

For microgrids operation planning, the concept of the dispatch strategy is essential. The economic dispatch (ED) contemplates the resolution of the Unit Commitment (UC) initially to determine the schedule with units that must start and stop to respond to the required demand [6]. Once the UC has been proposed, the economic dispatch (ED) is responsible for assigning, to the programmed units, the power references that must be generated to cover the demand at minimum cost at the same time, satisfy the physical constraints of the generating units (power balance, power generation limits) and the grid (power flow and voltage limits) [7].

As a result of the differences between traditional generation systems and microgrids, several publications in recent years have suggested new and different approaches and methods for solving ED and UC problems. For this purpose, for different microgrid structures, metaheuristic and heuristic methods have been proposed and applied to solve the problem of load dispatch [8], [9]. Some advanced control algorithms which consider system uncertainties, caused by demand and renewable sources of energy, have been developed to achieve optimal use of energy storage to compensate for physical imbalances, etc [10], [11], [12], [13].

Microgrid operation optimisation is extremely important to manage the energy resources efficiently. Due to the complexity of the optimisation problem and given the economic benefits that are achieved, attention has been paid to the improvement of optimisation algorithms.

Recently, Model-based Predictive Control (MPC) techniques are being applied to power systems. They provide a receding prediction horizon and a feedback mechanism which makes them a more robust tool against uncertainties. They also can handle constraints such as generating capacity and slack power production or consumption, limitation of work cycles and battery charging limits, etc.

In this article, the UC problem, considering the stochastic nature of the demand and the weather phenomena, is tackled. A novel type of electric market is considered within the microgrid in which the required demand is met with the power generated by the available local generation resources in real time. For this purpose, a Model Predictive Control (MPC) is solved at every time step to cover the demand regarding the uncertainties introduced by the prediction in the power variables. The hybrid microgrid is composed of generation units: wind turbine (WT), solar photo-voltaic panel (PV), diesel engine generator (DE), micro-turbine (MT), as well as storage devices such as Battery Energy Storage (BES), considering their constraints and the requirements of the generation reserve. The cost coefficients and constraints of conventional dispatchable units, renewable energy sources and BES are taken as data to solve the problem of stochastic unit commitment (SUC). The article is organised as following, section II presents the MPC formulation, presenting the cost function and the constraints. In section IV a case study will be used to compare the results obtained by a conventional scheduling based on forecasts performed only at the start of the scheduling period, and the proposed MPC strategy. The conclusion is given in section V.

II. MPC STRATEGY

In MPC, the controller runs a real-time optimisation to obtain the best solution for the control action [14]. MPC uses a dynamic model to predict the future behavior of the system. Setting a period of time of prediction (prediction horizon), an optimisation problem is solved to identify the best control action that minimizes a cost function related to the process predictions (see for instance Figure 1). In this case, the prediction model includes the selection of the generating units including the BES. The commitment status of the dispatchable resources is determined by the value of the binary variable $\delta_{it} \in \{0, 1\}$ where subindex i denotes the resource and subindex t denotes the time instant. For this study and regarding the low power capability of the generation units we will consider a negligible startup and shutdown time. Since all the generating units are dispatchable, the value 1 indicates commitment and 0 indicates shut down. In the case of the BES that has three working modes, 1 indicates

charging or discharging and the value 0 indicates that the BES is in standby (pause). The idea behind such control strategy is the optimisation of an objective function, calculating the appropriate sequence of inputs over a prediction horizon based on a model of the plant. Only the first control set point $u(1)$ is sent to the device and the whole process is repeated for the next sampling instant. Thus, continuous feedback of the control variable is obtained. The prediction horizon is always the same in each sample (a common thing in predictive control strategies). The difference is, with respect to any other optimal control strategy, the MPC is a *receding horizon* optimal control.

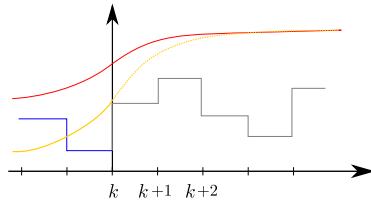


Fig. 1. Based on a model of the plant, the MPC algorithm solves an optimization problem to choose the best input to the system according to certain parameters. The figure shows a desired trajectory for a plant (red line). The blue and green lines represent the past input to the system and the past plant state, respectively. With that information the MPC solves the problem choosing a set of future control inputs (gray) and predicting the future state of the plant (green with dashed lines)

This continuous feedback allows errors to be assumed in the models. In fact, the stochastic nature of renewable energy production and demand makes MPC an adequate strategy against static planning through optimization. In the case of the microgrid, due to the lower granularity concerning the zone and the behavior of the demand, the uncertainty in the prediction is a growth factor with the prediction horizon. Figure 2 shows a set of real demand data, wind and solar power. The predictions have been artificially generated by adding an increasing uncertainty over time to the real data, to provoke a difference between predicted and real values when there are prediction uncertainties, as shown in graphs (b) and (c) in weather forecasts and the increasing error that the ARMA model used to predict demand, as shown in the graph (a).

III. SYSTEM MODELING

In this section the model of our problem is presented. We consider a hybrid microgrid composed of four generation units: wind turbine (WT), solar photo-voltaic panels (PV), diesel engine generator (DE) and a micro-turbine (MT). A battery energy storage (BES) system is also connected to the microgrid allowing us to use it as a generator or as a load in order to minimize the total cost of operation.

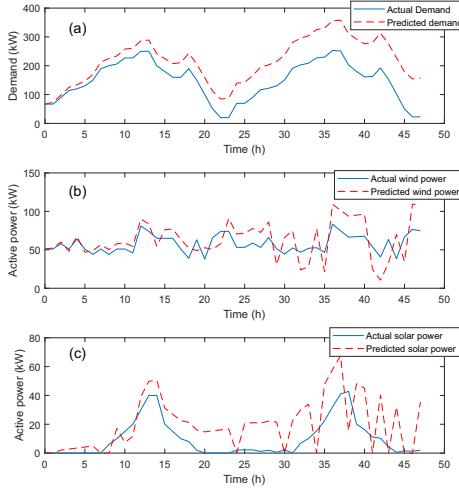


Fig. 2. Prediction models of renewable power and demand

A. Objective function

The main aim of our algorithm is to reduce the total cost of operation of the system. To do that let us consider the following cost function:

$$\min \sum_{i=DE,MT} \left(\sum_{t=k}^{k+N-1} (a_i \delta_{it} + b_i P_{it}) \right) \quad (1)$$

where $P_{it} \in \mathbb{R}$ is the power generated by the resource i at time instant t ; N is the prediction horizon of the MPC; and a_i and b_i are the startup and the marginal cost of generation unit i , respectively.

B. Constraints

The problem is subject to some physical constraints that must be fulfilled.

- Power balance

The total generation of all dispatchable distributed generators (DE,MT), renewable generation units (WT, PV) and BES must be equal to the system demands at every time step considered.

$$P_t^d = P_{DE,t} + P_{MT,t} + P_{WT,t} + P_{PV,t} + P_{BES,t} \quad (2)$$

for all $t \in [k, k + N - 1]$.

- Generation limits

The generation of each unit is bounded according to physical constraints:

$$P_{i,t} \delta_{i,t} \leq P_{i,t} \leq \bar{P}_{i,t} \delta_{i,t} \quad \forall i, \quad (3)$$

Where $P_{i,t}$ and $\bar{P}_{i,t}$ are the maximum and minimum amount of power that can be generated by generator i , respectively.

- Storage constraints

We define SOC_t as the state of charge of the battery at time t . The state of the charge of the battery is bounded according to the following inequality:

$$SOC_t \leq SOC_t \leq \overline{SOC} \quad \forall t \in [k, k + N - 1]. \quad (4)$$

Additionally, the state of the battery has the following dynamics:

$$SOC_t = SOC_{t-1} - P_{BES,t} \Delta t \quad (5)$$

where Δt is the time between consecutive time steps. Please, note that for this case of study we are considering an ideal battery storage system in which the charging and discharging efficiency is 100%.

Finally, it is worth pointing out that the generation of the battery at one concrete time instant is limited according to (3).

IV. SIMULATION AND RESULTS

This section presents the simulations results of the problem considered. The structure of the simulated microgrid is shown in Fig. 3. As it was mentioned before, it consists of a diesel engine (DE), a wind turbine (WT), a photovoltaic panel (PV), a diesel engine generator (DE) and a BES. The cost of fuel consumed by each disposable unit is modeled by a linear function. The Tables I and II show the technical and economic characteristics of each asset that forms the microgrid.

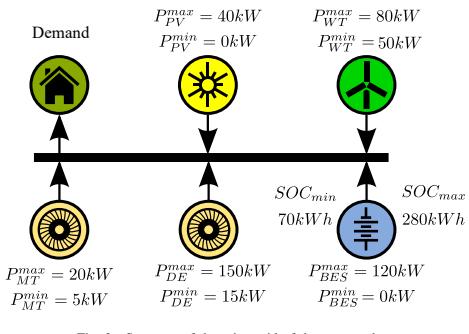


Fig. 3. Structure of the microgrid of the case study

A. Simulations results

In this case, for the MPC, prediction models such as those shown in Figure 2 have been used, where prediction errors increase over time. Figure 4 shows a comparison between a conventional UC, made by using the prediction models obtained at the first moment, and dynamic planning, based

TABLE I
TECHNICAL DATA OF GENERATOR UNITS [11]

Sources	P_{min} (kW)	P_{max} (kW)	SOC_{min} (kWh)	SOC_{max} (kWh)
DE	15	150		
PW	50	80		
PV	0	40		
BB	0	120	70	280

TABLE II
COSTS COEFFICIENTS OF GENERATOR UNITS [11]

DDG	Coefficient a	Coefficient b	Cost
DE	0,6	0,05	

on MPC, where at each sampling time (1 hour). Optimization is recalculated with new prediction models, displacing the time horizon ahead. Several issues can be observed:

- We can see in Figure 4(b) that MT is kept disconnected in both strategies, since its cost is higher than the other assets and the demand can be covered by them.
- In Figure 4(c), DE is operated less time and with less power by MPC strategy; it will result at less cost.
- Figure 4(d) shows that MPC strategy keeps the battery at more stable operation, since the demand is higher than the renewable production and the MPC searches for the optimum in each sample time, expending as much as possible from the battery. Nevertheless, this operational mode will increase the life of the BES device.
- We can observe in 4(e) how the MPC strategy keeps the SOC of the battery bank in optimum levels, avoiding full charges-discharges cycles, like in the Non-MPC strategy
- The simple UC strategy connects longer time the DG, being more expensive than the MPC scheduling. Figure 5 shows the contribution of dispatchable, renewable and energy storage systems.
- Finally, it can be seen in Table IV-A the final value of cost function (1) for conventional battery management strategies and using MPC. It can be seen that the MPC improves the performance of the problem achieving a better solution.

In the Figures 6 (a) and (b), the different power states of the battery bank and diesel group (in the rows from bottom to top) are shown according to the sampling time (columns). Thus, it can be seen in Figure 6 (a) , how the evolution of the battery management in the prediction horizon evolves, for instance, if we take column one, we can see the predicted power used by the battery in the following 24 hours, but only the action at time instant k is considered. Next, if we take the sequel column, we have the predictions of power from hour 1 to hour 25. It is worth mentioning that these predictions are not the same than the ones estimated at the previous instant due to the perturbations considered. The same reasoning works also for 6 (b), where the predictions of the power generated with the DE are shown.

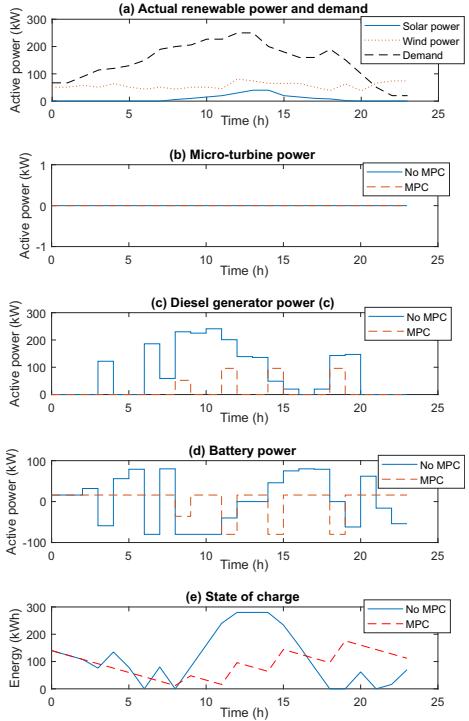


Fig. 4. Simulation results

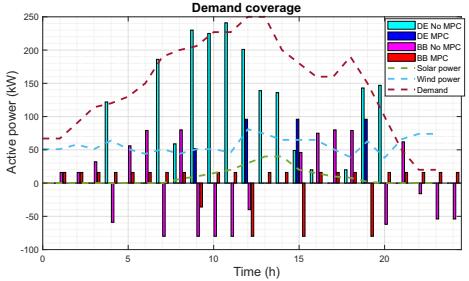


Fig. 5. Demand coverage by the available resources.

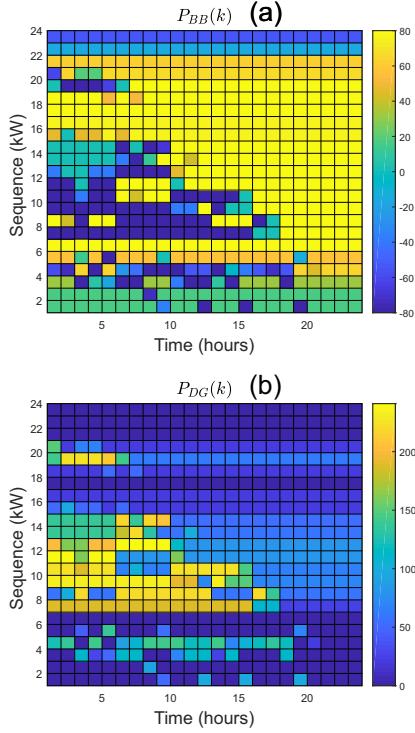


Fig. 6. Batery bank (a) and Diesel generator (b) power sequences

TABLE III
TOTAL COSTS/DAY (€) PER CONTROL STRATEGY

Without MPC	€104.3
With MPC	€19.4

V. CONCLUSION AND FUTURE WORK

An MPC strategy has been tested in a microgrid to obtain a minimum operation cost, compared to traditional UC, with a single optimization problem. The MPC has shown a better performance against modeling errors present in the predictions of demand and weather forecast.

A further work it will be interesting to explore the use of robust predictive control, taking into account in the optimization, the uncertainties of the problem guaranteeing stability. Additionally, the consideration of the model of the electrical grid will be considered also as a future work.

ACKNOWLEDGEMENT

The authors would like to acknowledge the financial support of the Spanish Ministry of Economy and Competitiveness under Grants PCIN-2015-043 and ENE2015-69597-R and AEI/FEDER by grant TEC2016-80242-P.

REFERENCES

- Hatzigianniou, Nikos D. and Kleftakis, Vasilis A. and Papadimitriou, Christina N. and Messinis, George M., "Microgrids in Distribution", Smart Grid Handbook, Wiley Online Library, pp. 1–24, 2016.
- Parhizi, Sina and Lotfi, Hossein and Khodaei, Amin and Bahramirad, Shay, "State of the art in research on microgrids: A review", IEEE Access, vol. 3, pp. 890–925, 2015.
- Parisiò, Alessandra and Rikos, Evangelos and Tzamalís, George and Glielmo, Luigi, "Use of model predictive control for experimental microgrid optimization", Applied Energy, vol. 115, pp. 37–46, 2014.
- Shah, Jalpa and Wollenberg, Bruce F and Mohan, Ned, "Decentralized power flow control for a smart micro-grid", Power and Energy Society General Meeting, 2011 IEEE, pp. 1–6, 2011.
- Olivares, Daniel E and Cähizares, Claudio A and Kazerani, Mehrdad, "A centralized energy management system for isolated microgrids", IEEE Transactions on smart grid, vol. 5, n 4, pp. 1864–1875, 2014.
- Zheng, Qipeng P and Wang, Jianhua and Liu, Andrew L., "Stochastic optimization for unit commitment:A review", IEEE Transactions on Power Systems, vol. 30, n 4, pp. 1913–1924, 2015.
- Dai, Hang and Zhang, Ni and Su, Wencong, "A literature review of stochastic programming and unit commitment", Journal of Power and Energy Engineering, vol.3, n 4, pp. 206-214, 2015.
- Nguyen, Minh Y and Yoon, Yong T and Choi, Nack H, "Dynamic programming formulation of micro-grid operation with heat and electricity constraints", Transmission & Distribution Conference & Exposition: Asia and Pacific, 2009, IEEE, pp. 1–4, 2009.
- Liang, HZ and Gooi, HB, "Unit commitment in microgrids by improved genetic algorithm", IPEC, 2010 Conference Proceedings, IEE, pp. 842–847, 2010.
- Talarji, Saber and Yazdaninejad, Mohsen and Haghifam, Mahmoud-Reza, "Stochastic-based scheduling of the microgrid operation including wind turbines, photovoltaic cells, energy storages and responsive loads", IET Generation, Transmission & Distribution, vol. 9, n12, pp. 1498–1509, 2015.
- Raj, Vinod M and Chanana, Saurabh, "Fuel cost optimization of an islanded microgrid considering environmental impact", Journal of Clean Energy Technologies, vol. 4 n 2, pp. 120–124, 2016.
- el Motaleb, Ahmad Mohamed Abd and Bekdache, Sarah Kazim and Barrios, Lázaro Alvarado, "Optimal sizing for a hybrid power system with wind/energy storage based in stochastic environment", Renewable and Sustainable Energy Reviews, vol. 59, pp. 1149–1158, 2016.
- Deckmyn, Christof and Van de Vyver, Jan and Vandenoorn, Tine L and Meersman, Bart and Desmet, Jan and Vandevelde, Lieven, "Day-ahead unit commitment model for microgrids", IET Generation, Transmission & Distribution, vol.11, n 1, pp. 1–9, 2017.
- Bordons C., Camacho, E.F. "Model Predictive Control. Second Edition. Ed. 2. Londres., Springer-Verlag. 2004. 426. ISBN 1-85233-694-3