



Centro de Investigación Científica de Yucatán, A.C.

Posgrado en ENERGÍA RENOVABLE

SISTEMA DE MANEJO DE ENERGÍA APLICADO A UN
VEHÍCULO MARÍTIMO AUTÓNOMO UTILIZANDO
TÉCNICAS DE CONTROL

Tesis que presenta

LUIS ORLANDO POLANCO VÁSQUEZ

En opción al título de

GRADO DOCTOR EN CIENCIAS EN ENERGÍA
RENOVABLE

Mérida, Yucatán, México

2022

CENTRO DE INVESTIGACIÓN CIENTÍFICA DE YUCATÁN, A. C.

POSGRADO EN CIENCIAS EN ENERGIA RENOVABLE



DECLARACIÓN DE PROPIEDAD

Declaro que la información contenida en la sección de Materiales y Métodos, los Resultados y Discusión de este documento proviene de las actividades de investigación realizadas durante el período que se me asignó para desarrollar mi trabajo de tesis, en las Unidades y Laboratorios del Centro de Investigación Científica de Yucatán, A.C., y que a razón de lo anterior y en contraprestación de los servicios educativos o de apoyo que me fueron brindados, dicha información, en términos de la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, le pertenece patrimonialmente a dicho Centro de Investigación. Por otra parte, en virtud de lo ya manifestado, reconozco que de igual manera los productos intelectuales o desarrollos tecnológicos que deriven o pudieran derivar de lo correspondiente a dicha información, le pertenecen patrimonialmente al Centro de Investigación Científica de Yucatán, A.C., y en el mismo tenor, reconozco que si derivaren de este trabajo productos intelectuales o desarrollos tecnológicos, en lo especial, estos se registrarán en todo caso por lo dispuesto por la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, en el tenor de lo expuesto en la presente Declaración.

Firma: 

Luis Orlando Polanco Vásquez

Mérida, Yucatán, México, a 31 de enero de 2022

CENTRO DE INVESTIGACIÓN CIENTÍFICA DE YUCATÁN, A. C.

POSGRADO EN CIENCIAS EN ENERGÍA RENOVABLE



RECONOCIMIENTO

Por medio de la presente, hago constar que el trabajo de tesis de Luis Orlando Polanco Vásquez titulado “**Sistema de manejo de energía aplicado a un vehículo marítimo autónomo utilizando técnicas de control**”, fue realizado en la unidad de energía renovable, área de sistemas híbridos, del Centro de Investigación Científica de Yucatán, A.C. bajo la dirección del Dr. Víctor Manuel Ramírez Rivera y codirección del Dr. Diego Langarica Córdova (adscrito a la Universidad Autónoma de San Luis Potosí), perteneciente al Programa de Doctorado en Ciencias en Energía Renovable de este Centro.

Atentamente

Dra. Cecilia Hernández Zepeda
Directora de Docencia

Mérida, Yucatán, México, a 31 de enero de 2022

AGRADECIMIENTOS

- a. Al financiamiento recibido por parte del CONACYT por la beca otorgada para la realización de esta investigación con el número de becario **641550**.
- b. Reconocimiento al proyecto del cual se recibió financiamiento **problemas nacionales 2015-01-786 de CONACYT**.
- c. Al laboratorio de sistemas híbridos de la unidad de energía renovable donde se realizó la investigación en el CICY y al centro de investigación CIESOL de la Universidad de Almería España de donde se obtuvieron datos para la realización de la investigación.
- d. A mi director de tesis el Dr. Víctor Manuel Ramírez quien colaboró con mi persona brindándome su conocimiento y apoyo en la realización de este trabajo de graduación.
- e. Al personal técnico académico de sistemas híbridos de energía de la unidad de energía renovable del CICY que colaboraron durante el desarrollo del proyecto de investigación brindando acceso al laboratorio mismo y las herramientas y equipos necesarios para desarrollar el proyecto.
- f. A mi esposa Julia Alexia Faustina Felipe por su amor y apoyo incondicional en estos años.
- g. A mis padres y hermanos por sus consejos apoyo y cariño que siempre me han brindado.

CONTENIDO

INDICE DE TABLAS.....	iii
INDICE DE FIGURAS.....	iii
TABLA ACRONIMOS	vi
RESUMEN.....	vii
ABSTRACT	viii
INTRODUCCIÓN.....	1
CAPITULO 1.....	3
ANTECEDENTES.....	3
1.1. Micro-redes de energía renovable.....	3
1.2. EMS para micro-redes de energía renovable	5
1.3. Evolución en el tiempo del estudio de EMS.....	8
1.4. Convertidores para Micro-redes en Vehículos Marítimos Autónomos	10
1.5. Optimización Multiobjetivo para micro-redes	12
1.6. Justificación	14
1.7. Hipótesis	14
1.8. Objetivo.....	15
CAPITULO 2.....	17
METODOLOGÍA.....	17
2.1. Modelado matemático	19
2.2. Banco de baterías	19
2.3. Aerogeneradores Tidal.....	21
2.4. Módulos fotovoltaicos.....	21
2.5. Cargas eléctricas	23
2.6. Convertidores CD-CD de potencia	23
2.7. Radiación solar	26
2.8. Métodos de series de tiempo para estimación de incertidumbres.....	28
2.8.1. Método de Doble Exponencial Suavizado	29
2.8.2. Método de Filtro de Kalman	30
2.8.3. Modelo de pronóstico persistente.....	31
CAPITULO 3.....	33

MODELO GENÉRICO DE OPTIMIZACIÓN PARA MICRO-REDES	33
3.1. Modelo explícito de optimización para micro-redes	34
3.1.1. Función Objetivo Mono objetivo	34
3.1.2. Funciones Objetivo Multiobjetivo	35
3.1.3. Restricciones de igualdad	36
3.1.4. Restricciones de desigualdad a funciones.....	37
3.1.5. Restricciones de desigualdad a variables.....	37
3.2. Modelo de MPC para micro-redes.....	39
3.3. Algoritmo genético (Método de optimización).....	42
3.3.1. Representación cromosómica	43
3.3.2. Función de selección.....	44
3.3.3. Operadores genéticos.....	45
3.3.4. Inicialización, terminación y evaluación de la función	46
3.4. Implementación computacional para el análisis de la optimización	47
3.5. Tomador de decisiones para optimización multiobjetivo.....	49
CAPÍTULO 4.....	51
RESULTADOS Y DISCUSIÓN	51
4.1. Resultados de algoritmo de optimización	51
4.2. Resultados de métodos de series de tiempo para predicción de radiación solar y velocidad de viento	55
4.3. Resultados de Modelo de Control Predictivo (MPC).....	59
4.3.1. Resultados de Modelo de Control Predictivo (MPC) para micro-red autónoma.....	60
4.3.2. Resultados de Modelo de Control Predictivo (MPC) para una micro-red no autónoma con función de costo constante.....	64
4.3.3. Resultados de Modelo de Control Predictivo (MPC) para función de costo variable en el tiempo	68
4.4. Resultados simulación de convertidores de potencia	72
4.5. Resultados optimización multiobjetivo.....	80
CONCLUSIONES.....	83
PRODUCTOS.....	85
PERSPECTIVAS	89
REFERENCIAS BIBLIOGRÁFICAS.....	91

INDICE DE TABLAS

Tabla 3.1 Diferencias generales entre algoritmos clásicos y genéticos.	43
Tabla 3.2 Estructura de tomador de decisiones.....	50

INDICE DE FIGURAS

Figura 1.1 Micro-red de vehículo marítimo autónomo (fuente propia).....	4
Figura 1.2. Niveles de control de una Micro-red (fuente propia)	5
Figura 1.3. Predicción de curvas de radiación solar (fuente propia).....	7
Figura 1.4. Evolución temporal de artículos científicos sobre EMS (fuente: Scopus).....	9
Figura 1.5. Evolución temporal de desarrollo de patentes de EMS (fuente: Patentscope).....	10
Figura 1.6. Sistema propuesto de convertidores para Micro-red (fuente propia).....	12
Figura 2.1. Esquema representativo de un banco de batería [10].....	21
Figura 2.2. Modelo esquemático de un módulo fotovoltaico [33]	22
Figura 2.3. Convertidores Buck-boost bidireccionales simplificado [35].....	24
Figura 2.4. Equivalente eléctrico de convertidor CD-CD bidireccional [35]	24
Figura 2.5. Convertidores Buck-boost simplificado [35]	26
Figura 2.6. Modelo de pronóstico persistente [39]	31
Figura 3.1. La estructura de un EMS	39
Figura 3.2. MPC	41
Figura 3.3. Estructura Básica de MPC [60].....	42
Figura 3.4. Algoritmo computacional de optimización para micro-redes (fuente propia)	49
Figura 4.1. Micro-red de estudio MCR1 (fuente propia).....	52
Figura 4.2. Curvas pronosticadas; a) demanda de potencia activa, b) irradiación solar y c) velocidad de viento. (fuente propia).....	53
Figura 4.3. Curvas de generación de la micro-red (fuente propia)	54
Figura 4.4. Estado de carga de la batería (SOC) (fuente propia).....	55

Figura 4.5. Predicción de Irradiancia y Potencia PV (fuente CIESOL)	56
Figura 4.6. Predicción de Velocidad de viento y Potencia Aerogenerador (fuente CIESOL)	56
Figura 4.7. RMSE de la irradiación solar (fuente propia)	58
Figura 4.8. RMSE de la velocidad de viento (fuente propia)	58
Figura 4.9. Predicción de Irradiancia y Potencia PV de un día de invierno nublado (fuente CIESOL).....	59
Figura 4.10. Predicción de velocidad de viento y potencia de aerogenerador para un día de invierno nublado (fuente CIESOL).....	59
Figura 4.11. Curvas pronosticadas para MCR2; a) irradiación solar, b) velocidad de viento y c) demanda de potencia activa, (fuente CIESOL).....	61
Figura 4.12. Micro-red de prueba MCR2	62
Figura 4.13. Curvas de generación de la micro-red MCR2 (fuente propia)	63
Figura 4.14. Curvas de potencia MCR2; a) SOC Batería, b) Déficit de energía en MCR2 y c) Energía Amortiguada en MCR2. (fuente propia).....	63
Figura 4.15. SOC Batería MCR2 (fuente propia)	64
Figura 4.16. Micro-red de estudio MCR3 (fuente propia)	65
Figura 4.17. Curvas pronosticadas para MCR3; a) irradiación solar, b) velocidad de viento y c) demanda de potencia activa, (fuente CIESOL).....	65
Figura 4.18. Curvas de generación de la micro-red MCR3 con N=10 (fuente propia)	66
Figura 4.19. Curvas de generación de la micro-red MCR3 con N=4 (fuente propia).....	67
Figura 4.20. SOC Batería MCR3 (fuente propia)	67
Figura 4.21. Micro-red de estudio MCR4 (fuente propia)	68
Figura 4.22. Curvas pronosticadas para MCR4; a) irradiación solar, b) velocidad de viento y c) demanda de potencia activa, (fuente CIESOL).....	69
Figura 4.23. Curvas de generación de la micro-red MCR4 con N=10 (fuente propia)	70
Figura 4.24. Comportamiento de funciones de costo MCR4 (fuente propia).....	71
Figura 4.25. SOC Batería MCR4 (fuente propia)	72
Figura 4.26. diseño de convertidor Buck-boost en lazo abierto.....	73
Figura 4.27. Función de transferencia en lazo abierto (fuente propia)	73

Figura 4.28. Diagrama de polos y ceros convertidor Buck-boost (fuente propia)	74
Figura 4.29. Función de transferencia en lazo cerrado (fuente propia)	74
Figura 2.47. Circuito de convertidor en lazo cerrado (fuente propia).....	75
Figura 4.31. Voltaje del convertidor en lazo cerrado (fuente propia)	75
Figura 4.32. Convertidor Buck-boost bidireccional en lazo abierto (fuente propia).....	76
Figura 4.33. Funciones de transferencia en lazo abierto (fuente propia)	76
Figura 4.34. Salidas de voltaje del convertidor en lazo abierto (fuente propia)	77
Figura 4.35. Diagrama de polos y ceros convertidor Buck-boost bidereccional (fuente propia) .	77
Figura 4.36. Convertidor Buck-boost bidireccional en modo carga (fuente propia)	78
Figura 4.37. Parámetros de convertidor en modo carga, a) SOC batería b) Corriente de carga c) Voltaje de carga	78
Figura 4.38. Convertidor Buck-boost bidireccional en descarga	79
Figura 4.39. Parámetros del convertidor en modo descarga, a) SOC batería b) Corriente de descarga c) Voltaje de descarga	79
Figura 4.40. Pronóstico de potencia con N = 10 (Soluciones de los extremos).....	81
Figura 4.41. Pronóstico de potencia con N = 10 (Soluciones nominadas)	81
Figura 4.42. Comparación de tiempo de cómputo algoritmos mono objetivo y multiobjetivo.....	82

TABLA ACRONIMOS

<i>Abreviatura</i>	<i>Significado</i>
AG	Algoritmos genéticos
ANN	Artificial Neural Networks
ARIMA	AutoRegressive Integrated Moving Average
ARMA	AutoRegressive Moving Average models
CA	Corriente alterna
CD	Corriente directa
CICY	Centro de investigación científica de Yucatan
CIESOL	Centro de investigación en energía renovables
CO ₂	Dióxido de carbono
CSA	Cuckoo Search Algorithm
DES	Doble exponencial suavizado
EMS	Energy Management System
EPA	Agencia de Protección Ambiental
GOA	Grasshopper Optimisation Algorithm
ICD	Indicadores clave de desempeño
MCR1	Micro-red 1
MCR2	Micro-red 2
MCR3	Micro-red 3
MCR4	Micro-red 4
MITECO	Ministerio para la Transición Ecológica y el Reto Demográfico de España
MPC	Model predictive control
ODM	Opción de diseño múltiple
PID	Proporcional Integral derivativo
PSO	Particle swarm optimization
PV	PhotoVoltaic
RMSE	Root-mean-square error
SOC	State of charge

RESUMEN

En este trabajo se investigan los sistemas de gestión energética para micro-redes, aplicados en vehículos marítimos autónomos. El objetivo es abordar el diseño y simulación de un sistema de gestión energética para optimizar una micro-red, teniendo en cuenta las incertidumbres y la naturaleza estocástica asociada a la energía solar y eólica y la demanda de la carga. Para este objetivo, se propone un modelo de optimización estocástica que integra técnicas de control predictivo basado en modelo (MPC); este modelo está integrado a través de una red de distribución. Puede ser en corriente continua o alterna en modo autónomo y no autónomo en este trabajo, se abordan los diferentes casos y se realizan simulaciones. Los métodos utilizados para predecir la radiación solar y la velocidad del viento se basan en series de tiempo; estos están integrados con el MPC para controlar en tiempo real. Además, se desarrolla un caso que se resuelve con optimización multiobjetivo para tener en cuenta la reducción de CO₂, teniendo en cuenta no solo el aspecto económico sino también el ambiental. Su aplicación a diferentes casos prácticos verifica la eficiencia y eficacia de la integración del sistema de gestión energética. El primer caso es para un vehículo marítimo autónomo en la ciudad de Cancún, Quintana Roo, México. También hay otros casos en la Universidad de Almería, primero en un vehículo terrestre de prueba y, posteriormente, en el edificio bioclimático CIESOL en la ciudad de Almería, España.

ABSTRACT

In this work, energy management systems for microgrids, applied in autonomous maritime vehicles, are investigated. The objective is to approach the design and simulation of an energy management system to optimize a microgrid, taking into account the uncertainties and the stochastic nature associated with solar and wind energy and the demand of the load. For this objective, a stochastic optimization model is proposed that integrates model predictive control techniques (MPC); this model is integrated through a distribution network. It can be in direct current or alternating current in autonomous mode and not autonomous in this work, the different cases are approached, and simulations are carried out. The methods used to predict solar radiation and wind speed are based on time series; these are integrated with the MPC to control in real-time. In addition, a case is developed that is solved with multi-objective optimization to take into account the reduction of CO₂ counts not only the economic aspect and the environmental one. Its application to different case studies verifies the efficiency and effectiveness of integrating the energy management system. The first case is for an autonomous maritime vehicle in the city of Cancun Quintana Roo, Mexico. There are also other cases in the University of Almería, first in a test land vehicle and, later, in the CIESOL bioclimatic building in the city of Almería, Spain.

INTRODUCCIÓN

Para la propulsión de vehículos marítimos autónomos, se necesita contar con un centro de distribución de energía eléctrica para la alimentación de los motores que lo impulsan, una solución viable es el uso de fuentes de energía renovable integradas en una micro-red dentro del vehículo marítimo. Así pues, es de vital importancia el manejo óptimo de las fuentes de energía en las micro-redes por lo cual el estudio del Sistema de Manejo de la Energía (EMS del inglés *Energy Management System*) para micro-redes es primordial. Este tema ha comenzado a ser ampliamente investigado, sin embargo, en la mayoría de los trabajos realizados no se toma en cuenta la incertidumbre de la generación de energía renovable como la solar, eólica, mareomotriz y la demanda de carga, además de realizar los controles con métodos analíticos que funcionan bien bajo ciertas condiciones climáticas normales, pero no realizan un buen control teniendo en cuenta las incertidumbres antes mencionadas. En el presente trabajo de tesis se aborda el desarrollo de un EMS para micro-redes autónomas implementada en un vehículo marítimo autónomo cuya aplicación concierne la investigación de los hábitos alimenticios del pez león, además se realizará simulaciones para un EMS implementado para un edificio bioclimático conectado a la red principal.

Se seleccionarán escenarios con diferentes condiciones climatológicas para un intervalo de 24 horas mediante diferentes métodos estocásticos y técnicas de control predictivas que consideran la incertidumbre de acuerdo con patrones utilizados propios de la generación de energía renovable, además de tomar en cuenta los sistemas de almacenamiento. Esta etapa del proyecto es primordial y se realizará para procesar los datos de perfiles de radiación solar y velocidad de viento, la implementación del control predictivo y métodos estocásticos se realizará al tener los modelos matemáticos unificados de los diferentes elementos de la micro-red.

Dentro del trabajo propuesto se considera el desarrollo de controladores terciarios para EMS de micro-redes como se mencionó anteriormente utilizando métodos estocásticos con técnicas de control predictivas que presentan una mejor respuesta con sistemas que introducen incertidumbre como los sistemas de generación de energía renovable y la demanda de la carga, estos se unificarán para permitir la comparación y la validación mediante el manejo de la energía de la micro-red simulada en el vehículo marítimo autónomo de monitoreo de hábitos alimenticios del pez león y el edificio bioclimático. En el modelo de la micro-red se incluyen convertidores de potencia de tipo Buck-boost y Buck-boost bidireccionales, todos conectados a

un mismo bus de corriente directa (CD) regulado para la alimentación de los motores del vehículo y la gestión del sistema de almacenamiento para su carga y descarga, estos se modelarán matemáticamente además se realizará la simulación.

Adicionalmente el modelo de la micro-red se construye por medio de métodos de optimización de un solo objetivo y multiobjetivo, integrando el MPC para optimizar el costo de energía de la red principal y la emisión de CO₂ al ambiente de micro-red. La aplicación se puede dirigir a la industria de la electricidad; también la optimización multiobjetivo toma en cuenta aspectos que hacen más realista la solución de los problemas.

En el trabajo se realizará la simulación de un problema dinámico en el que se resuelve el problema de optimización en línea cuando cambian las condiciones del trabajo, este presenta la ventaja de poder realizar el control en tiempo real.

CAPITULO 1.

ANTECEDENTES

Los vehículos marítimos autónomos se utilizan para diferentes aplicaciones en la actualidad, tales como el monitoreo de especies marinas, la ecología marina, operaciones de búsqueda y rescate entre otras. El manejo de la energía para su funcionamiento puede ser con sistemas de almacenamiento conectados a una micro-red de energía renovable autónoma.

1.1. Micro-redes de energía renovable

El uso eficiente de la energía en cualquier ámbito se ha vuelto primordial debido a aspectos ambientales, económicos y de operación por lo cual es de vital importancia el estudio del manejo de energía en una micro-red. Las micro-redes pueden clasificarse de acuerdo con su operación en autónomas y no autónomas, la utilización de las micro-redes autónomas se puede dar en áreas rurales y en la utilización de equipos que necesitan autonomía de energía para su funcionamiento como vehículos del espacio, vehículos marítimos autónomos u otros en donde no se pueda conectar a la red de distribución de energía [1], [2]. Las redes no autónomas se pueden ver en redes residenciales, industriales y hoy en día algunos vehículos autónomos en los cuales se conectan a una red general de distribución de energía ya sea para exportar o importar energía para su funcionamiento. Sin embargo, el uso eficiente de micro-redes es difícil debido a la presencia de recursos energéticos distribuidos, que pueden ser controlables (o despachables), tales como turbinas de gas o motores diésel, pero también no controlables (o no despachables), como turbinas eólicas o generadores fotovoltaicos (*PV del inglés PhotoVoltaic*), generadores mareomotrices cuya producción depende en gran medida de las condiciones climáticas, que a su vez se pueden pronosticar durante largos períodos con cierta incertidumbre [1], [2]. Además, las cargas sufren de los mismos problemas de incertidumbre: mientras que las predicciones acertadas se pueden hacer dentro de un día, todavía hay un componente estocástico el cual tiene que ser considerado. Para mitigar estas incertidumbres, se puede importar o exportar energía de la red de servicios públicos, si está conectada, o incluir dispositivos de almacenamiento en las micro-redes, como las baterías u otros sistemas de almacenamiento, los cuales tienen que ser manejados apropiadamente para suplir las necesidades de demanda del sistema el cual no está conectado a la red [3]. El concepto de fuente de energía intermitente define que es cualquier fuente de energía que no está continuamente disponible para su conversión en electricidad y control directo externo porque

la energía primaria utilizada no se puede almacenar [3], este concepto es útil para el análisis de las energías renovables.

En general, una micro-red puede definirse como un conjunto de cargas y fuentes de energía distribuida que son operadas de manera coordinada, controladas de manera descentralizada y percibidas como una entidad única por la red principal (sistema eléctrico) [4]. Además, contribuyen a la preservación del medio ambiente y sustentabilidad energética ya que reducen las pérdidas en las líneas de distribución, mitigan la expansión de la red principal y pueden emplearse para proveer energía eléctrica a zonas rurales, vehículos espaciales y vehículos marítimos autónomos entre otros beneficios [5]. Por ejemplo, en la Figura 1.1. se muestra una micro-red de tipo autónoma.

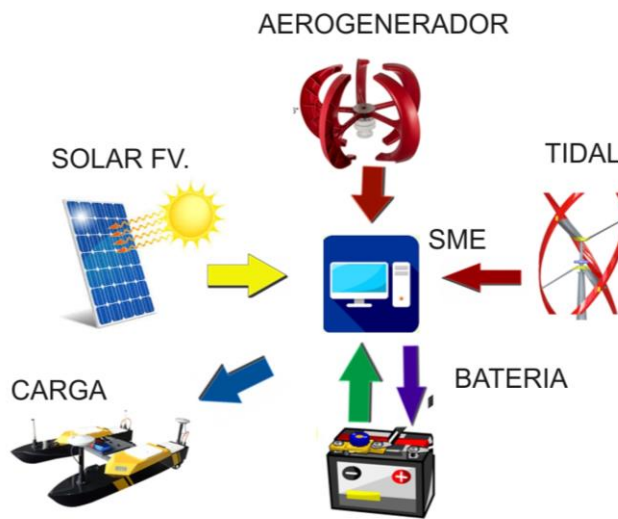


Figura 1.1 Micro-red de vehículo marítimo autónomo (fuente propia)

En cualquiera de los modos de operación de la micro-red, el control se realiza por medio de un control jerárquico de tres niveles: control primario, control secundario y control terciario como se muestra en la Figura 1.2. este trabajo se enmarca en la parte del control terciario como un EMS de micro-redes operado en modo autónomo. En este escenario, los objetivos que principalmente se persiguen es la operación apropiada del elemento de almacenamiento para suplir la necesidad de la demanda además de cumplir con los valores operativos adecuados para aplicaciones en áreas rurales, vehículos espaciales o vehículos marítimos autónomos [5]. La micro-red operada en modo no autónomo gestiona principalmente la energía de la red

principal optimizando en algunos casos optimizando el costo de la energía y otras reduciendo la cantidad de energía provenientes de fuentes no renovables [6].

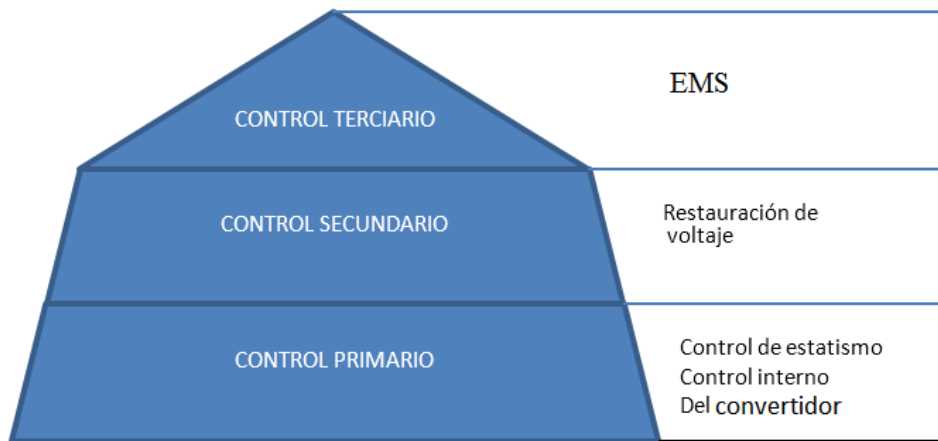


Figura 1.2. Niveles de control de una Micro-red (fuente propia)

1.2. EMS para micro-redes de energía renovable

Las técnicas de control predictivo son métodos que permiten manipular las variables de control para establecer una trayectoria deseada de la variable a controlar en el futuro [7]. Esta técnica se utiliza para construir una estrategia de control terciario para EMS de la micro-red. El modelo de control predictivo deslizante (MPC del inglés *Model Predictive Control*) utiliza un modelo explícito para predecir la salida del proceso en instantes futuros. El cálculo de las variables de control se realiza optimizando una función objetivo mediante método de enjambre de partículas o algoritmos genéticos y siguiendo un horizonte móvil deslizante, es decir, se calcula un vector de variables de control a lo largo de un horizonte de control donde solo se aplicarán los valores asociados al instante actual, de tiempo t , descartando todos los demás, en el siguiente tiempo de muestreo, $t+1$, con información de las variables actualizadas se volverá a optimizar la función de coste para volver a calcular el vector de variables de control. Esta característica se denomina horizonte. Merece la pena destacar que el MPC es una técnica muy potente que permite formular controladores para sistemas complejos y con restricciones. En este caso se ha venido utilizando para la gestión de energía en micro-redes debido a las ventajas que se obtienen con el manejo de restricciones y la facilidad que da al poder utilizar métodos estocásticos para tomar en cuenta la incertidumbre que introduce la energía renovable. Consecuentemente, el análisis mediante el método de Montecarlo para la parte estocástica es una herramienta principal para el desarrollo del EMS [5], [8], [9].

Como ya sabemos la energía fotovoltaica, la energía eólica y la energía mareomotriz pueden tener errores de predicción considerables con incertidumbres en la radiación solar, velocidad del viento, comportamiento de las olas y demandas locales, y requiere un análisis estocástico para obtener la solución más adecuada a la situación real. El problema de un EMS consiste en determinar de manera óptima qué fuentes de energía deben de operar en un horizonte de evaluación de corto plazo, que por lo general varía, dependiendo de las características técnicas de las fuentes de energía. El EMS que usa métodos estocásticos para la determinación de incertidumbres se utiliza para la toma de decisiones bajo incertidumbre, el tomador de decisiones tiene que encontrar la decisión óptima a lo largo de un horizonte de tiempo, utilizando información incompleta. Dentro de ese horizonte considerado, un cierto número de etapas son definidas, cada etapa representa un punto en el tiempo donde deben tomarse decisiones o cuando la incertidumbre desaparece total o parcialmente. Para obtener estos resultados es necesario desarrollar un modelo probabilístico de asignación de carga capaz de demostrar la estocástica asociada a las fuentes de energía renovables y también capaz de acomodar las salidas aleatorias de las tecnologías tradicionales. También es necesario definir una formulación de generación de energía eólica, fotovoltaica y mareomotriz que pueda ser utilizada dentro de este modelo probabilístico. Por lo que una nueva formulación de la aleatoriedad de la energía eólica mareomotriz y de la energía fotovoltaica es necesaria para un marco de programación estocástico [10]. Tradicionalmente la demanda de carga también se ha considerado como una fuente importante de incertidumbre que requiere atención específica para el funcionamiento del sistema [11], [12], [13], [14]. La Figura 1.3 muestra la predicción de radiación solar realizada para un día de invierno despejado, un día de invierno nublado, un día de verano despejado y un día de verano nublado de la ciudad de Cancún, estas graficas se obtuvieron de los datos del servicio meteorológico nacional de México. La fuente de energía intermitente es cualquier fuente de energía que no está continuamente disponible para su conversión en electricidad y control directo externo porque la energía primaria utilizada no se puede almacenar. Las fuentes de energía intermitentes pueden ser predecibles, pero no pueden enviarse para satisfacer la demanda de un sistema de energía eléctrica.

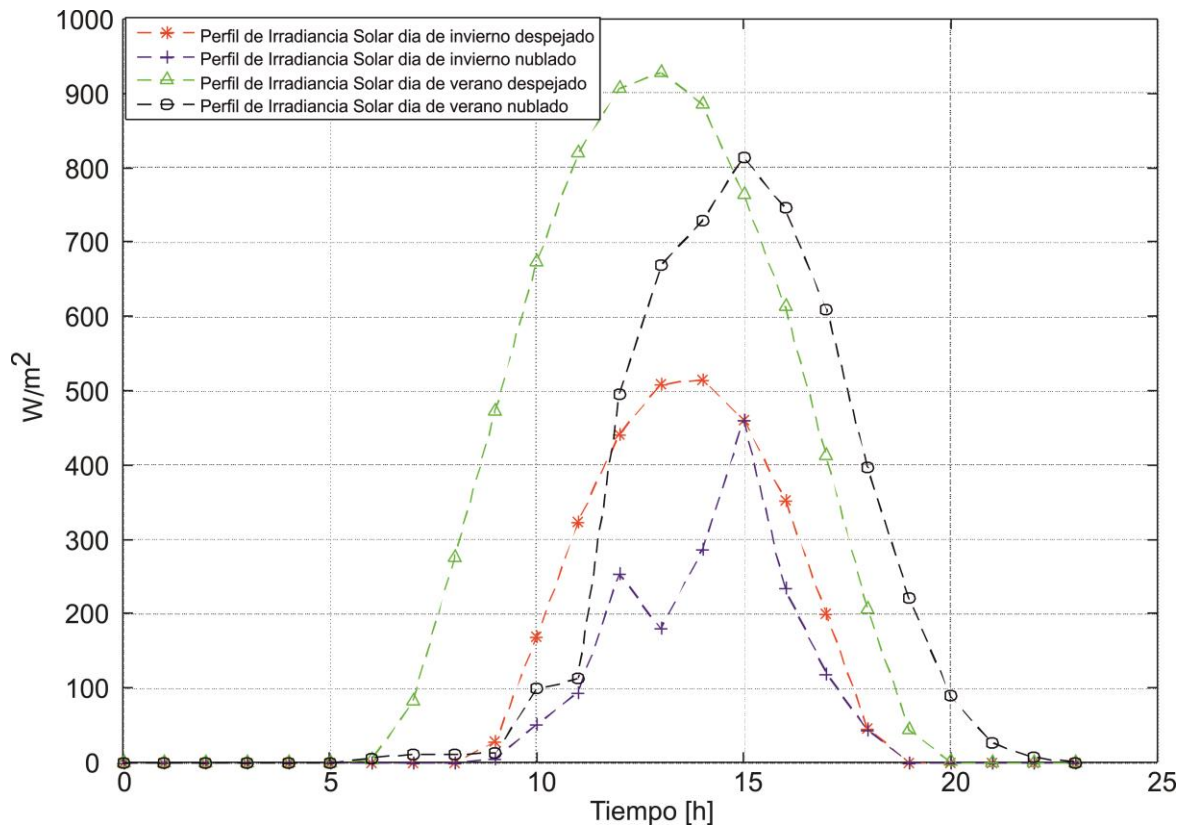


Figura 1.3. Predicción de curvas de radiación solar (fuente propia)

Existen muchos métodos para estimar las incertidumbres y se pueden caracterizar por la longitud del horizonte de predicción y la metodología seleccionada. El horizonte de predicción puede variar según la aplicación y puede considerarse a corto plazo para la predicción de hasta 60 minutos [15], o predicción a largo plazo para valores de predicción por hora, día y mes [16]. Por otro lado, las variables de incertidumbre generalmente se representan como estructuras de series temporales debido principalmente a su comportamiento estocástico. Los modelos de series temporales son una de las formas de estimar los valores futuros de las incertidumbres. Estos modelos se obtienen utilizando datos pasados y se utilizan para estimar el comportamiento futuro a lo largo de un horizonte de predicción [9]. Los modelos de series de tiempo se basan en el supuesto de que los datos modelados están autocorrelacionados y se caracterizan por tendencias y variaciones estacionales. Por lo tanto, modelos bien conocidos autocorrelacionados (*ARMA del inglés AutoRegressive Moving Average models*, *ARIMA del inglés AutoRegressive Integrated Moving Average*) también podrían usarse para la estimación de incertidumbres [17], [15]. Por otro lado, las redes neuronales artificiales (*ANN del inglés Artificial Neural Networks*) también proporcionan una buena solución para realizar estimaciones porque su diseño se basa en el entrenamiento y no se necesitan suposiciones estadísticas para

los datos de origen. Las redes neuronales son ampliamente aceptadas como una tecnología para predecir series de tiempo que ofrecen una forma alternativa de resolver problemas complejos [18]. Este trabajo se enfoca en modelos de series de tiempo como una aproximación al problema de estimación de incertidumbres. Por lo tanto, este trabajo aborda la predicción de incertidumbres basada en los métodos de análisis de series de tiempo [19]. El objetivo principal de los métodos seleccionados es predecir el valor futuro basado únicamente en las mediciones pasadas con un horizonte de predicción específico. Los métodos elegidos pueden usarse para predecir incertidumbres, especialmente variables climáticas con el objetivo de usarse en estrategias de control predictivo.

Una serie de tiempo es una secuencia continua $x(t)$ o discreta de cantidades medidas, tomadas de la actividad humana o de algún sistema físico. Las metas principales en el análisis de series de tiempo son: predicción, modelado y caracterización. El análisis de series de tiempo se puede aplicar para identificar la naturaleza del fenómeno representado por la secuencia de observaciones. Los datos de series temporales a menudo surgen durante el monitoreo de procesos industriales o variables meteorológicas. Existe una diferencia esencial entre el modelado basado en métodos de series de tiempo y los métodos de análisis de series de tiempo. El análisis de series de tiempo explica el hecho de que los puntos de datos tomados a lo largo del tiempo pueden tener una estructura interna (como autocorrelación, tendencia o variación estacional) que debe tenerse en cuenta [20]. El modelo de series de tiempo requiere que se identifique el patrón de los datos de series de tiempo observados. Una vez establecido el patrón, podemos propagarlo a tiempo con las tendencias obtenidas e integrarlo con otros datos. En este documento, se analizan y comparan tres métodos de series de tiempo bien conocidos, Filtro de Kalman discreto [21], Método de la persistencia [22] y Método de doble exponencial suavizado [20]. Estos métodos se utilizan para obtener pronósticos de la radiación solar y velocidad de viento utilizando datos reales tomados de una estación meteorológica del edificio de CIESOL en la Universidad de Almería España. Se utilizan varias mediciones de verificación para comparar los resultados obtenidos entre los diferentes métodos de estimación.

1.3. Evolución en el tiempo del estudio de EMS

Como parte de los antecedentes se realizó una revisión de la evolución temporal del desarrollo de patentes y artículos que se han realizado en los últimos años acerca de los EMS. Primero se hizo un análisis de la evolución en el tiempo de artículos acerca del tema, esta se hizo con la base de datos Scopus que nos proveyó de la siguiente información.




Figura 1.4. Evolución temporal de artículos científicos sobre EMS (fuente: Scopus)

Como se observa en la Figura 1.4, el tema se comenzó a estudiar desde el año 1970 pero realmente no tuvo un repunte hasta el año 2006 donde las grandes potencias industriales como Estados Unidos y China intensificaron los esfuerzos en su estudio y desarrollo debido al auge de las energías renovables que se produjo en estos años. El desarrollo de artículos científicos sobre EMS sigue estando vigente porque todavía la eficiencia energética en las micro-redes es un tema que se puede mejorar.

Referente al desarrollo de patentes de EMS como se dijo anteriormente hasta el año 2006 se tuvo un repunte en el estudio del tema por lo cual los primeros registros de EMS patentadas aparecen hasta el año 2009 como podemos ver en la Figura 1.5.

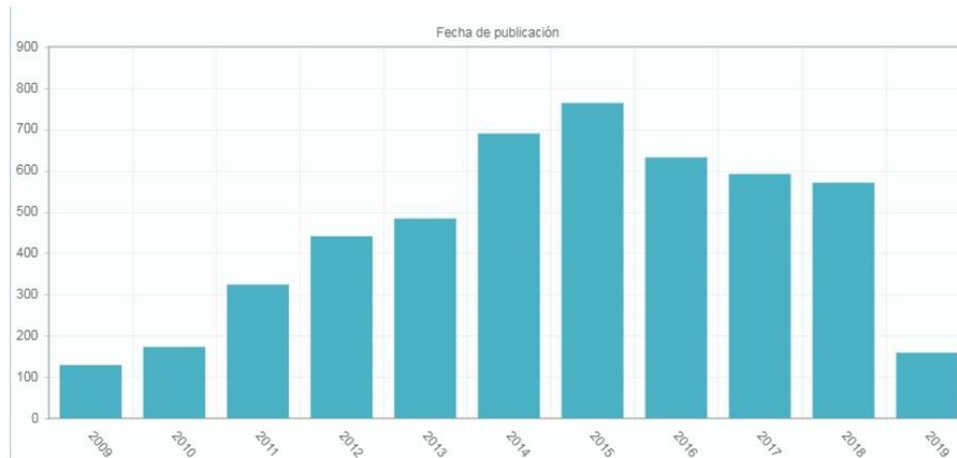


Figura 1.5. Evolución temporal de desarrollo de patentes de EMS (fuente: Patentscope)

En la Figura 1.5 se muestra el comienzo de registros de patentes y su evolución hasta la fecha, se observa que las patentes tuvieron un crecimiento constante hasta el año 2015, de este año en adelante ha experimentado una baja en el desarrollo de las patentes, pero hasta el año actual se ve que un tema que se mantiene vigente por lo cual es importante el estudio de este tema.

1.4. Convertidores para Micro-redes en Vehículos Marítimos Autónomos

En la actualidad se han reportado muchas topologías de sistemas de convertidores para diferentes aplicaciones en especial para micro-redes. Por ejemplo en [23] se evalúan cuatro diferentes topologías, una de estas toma energía de dos fuentes en paralelo mediante una etapa CD-CD y estas realizan la regulación en un bus CD, después entra a una etapa de inversor CD-CA, en una segunda topología se toma energía de una celda de combustible mediante una etapa CD-CD esta es regulada en un bus CD para cargar la batería y después pasar a la etapa de inversor, en una tercera topología una etapa CD-CD toma energía de la batería y la regula al voltaje necesario para luego alimentar la celda de combustible y en una cuarta topología cada fuente tiene una etapa de CD-CD donde dos de ellas mantienen la regulación en el bus CD y el inversor se alimenta de éste, la cuarta topología tiene la ventaja que nos permite obtener el punto de máxima potencia de las fuentes que lo alimentan [24], [25], [26].

Otro de los temas que se estudiaron en la literatura fue las diferentes topologías de conexión de baterías y paneles fotovoltaicos. En [27] se analiza un convertidor Buck-boost bidireccional con

seguimiento de punto de máxima potencia usando un simulador de arreglo de paneles fotovoltaicos, en éste se implementa un algoritmo de optimización de enjambre de partículas (*PSO del inglés particle swarm optimization*) para el seguimiento del punto máximo de potencia. En [28] se implementa un convertidor Buck-boost bidireccional para el sistema de almacenamiento de un vehículo eléctrico enchufable, desarrollando una nueva forma de calcular la eficiencia del convertidor donde se muestra que el convertidor Buck-boost puede llegar hasta una eficiencia del 95% siendo este el mejor en valor de eficiencia. En [29] se presenta una nueva topología de Buck-boost aislada Bidireccional CD-CA trifásico, para interconectar una micro-red CD se implementa una estrategia de conmutación para disminuir la distorsión armónica. En [30] se explica que una de las razones por las que se utilizan convertidores en estos sistemas, es la de realizar seguimiento de MPPT. Una topología de un sistema aislado que se presenta en [31], muestra el convertidor Buck que toma energía del panel solar para mantener un bus de CD y un convertidor Buck-boost bidireccional que en modo Buck toma energía del Bus de CD para cargar la batería, y en modo Boost toma energía de la batería para contribuir a mantener el Bus de CD junto con el otro convertidor, este tipo de topología es muy utilizada para micro-redes aisladas y CD que son las que se utilizan para vehículos autónomos [32].

En la Figura 1.6 se muestra la configuración de la micro-red propuesta para el vehículo marítimo autónomo la cual está conformada por un sistema fotovoltaico, aerogenerador, generador mareomotriz de tipo tidal y sistema de almacenamiento. El sistema fotovoltaico se conecta al bus CD por medio de un convertidor Buck-boost, para elevar o reducir el voltaje dependiendo de la necesidad, el aerogenerador y el generador tidal de la misma forma se conecta al bus CD por un convertidor Buck-boost respectivamente. El sistema de almacenamiento se conecta al Bus CD por medio de un convertidor Buck-boost bidireccional que permite la carga y descarga con los niveles de voltaje adecuados. El bus CD alimenta directamente a los motores que mueven el vehículo marítimo autónomo. La nomenclatura de la Figura 1.6 es la siguiente:

P_{CDk} representa la potencia del sistema fotovoltaico, P_A representa la potencia del aerogenerador, P_T representa la potencia de generador tidal, P_{Bcj} y P_{Bcdj} representan la potencia de carga y descarga de la batería respectivamente.

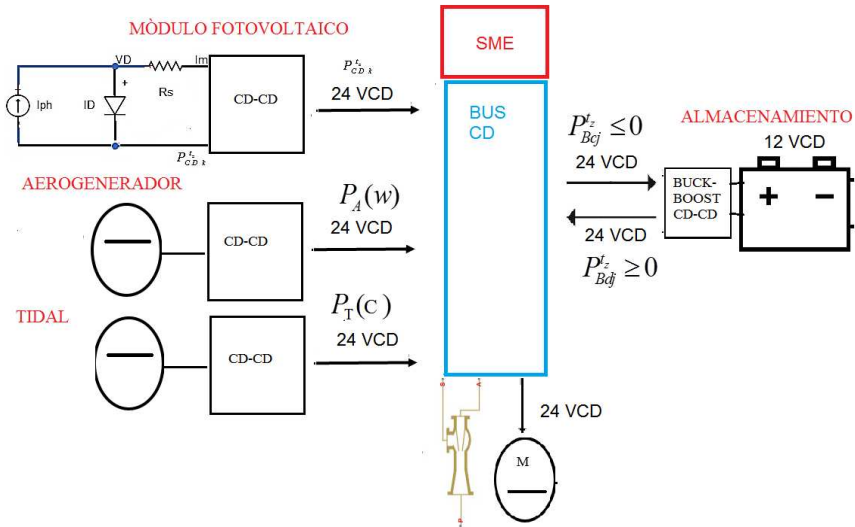


Figura 1.6. Sistema propuesto de convertidores para Micro-red (fuente propia)

1.5. Optimización Multiobjetivo para micro-redes

El estado del arte realizado para este trabajo incluye investigaciones recientes sobre técnicas de optimización multiobjetivo aplicadas a EMS, algunos de los pocos trabajos encontrados presentan buenos resultados utilizando técnicas de optimización multiobjetivo. Algunos ejemplos de investigación se describen a continuación.

Fioriti et al. [33] Propone un enfoque de solución multiobjetivo que no solo tenga en cuenta el enfoque económico sino también el social que afecta al entorno empresarial, además no solo se calcula el tradicional frente de pareto, sino que además compile soluciones de compromiso que amplíen el portafolio de opciones para los desarrolladores de micro-redes, este trabajo presenta un caso de estudio híbrido en Kenia donde la opción de diseño múltiple (ODM) hace que el método utilizado como método de toma de decisiones se apoye en un análisis de indicadores clave de desempeño (ICD), se demuestra que comprometen las soluciones también puede ser viable para diferentes escenarios en los que se implementan las micro-redes. En [34] se presenta el diseño de micro-redes, siendo una actividad costosa y arriesgada al utilizar varios índices económicos para optimizar y evaluar la rentabilidad; cada índice presenta ventajas y desventajas, respectivamente. Realizar una optimización de un solo objetivo puede conducir al desarrollo de un diseño erróneo. El trabajo propone un enfoque multiobjetivo que optimiza al mismo tiempo diferentes indicadores económicos. Los resultados muestran que el proceso multiobjetivo proporciona soluciones de compromiso a través de múltiples objetivos, satisfaciendo el entorno desafiante que hace que las micro-redes se implementen. Bouchekara et al. [35] en este trabajo, presenta un problema de optimización multiobjetivo considerando el

costo de la energía eléctrica y la probabilidad de pérdida de suministro de energía. Se estudia un caso de micro-red para campamentos en el desierto de Hafr Al-Batin en Arabia Saudita. La micro-red se conectará a la red principal. El problema se resolvió utilizando el algoritmo evolutivo multiobjetivo basado en dominancia y descomposición. En esta investigación, se muestran el frente de Pareto y todas las soluciones de compromiso. La solución más adecuada se elige según el criterio del diseñador y las características de la micro-red. En [36], se propone un EMS basado en reglas optimizado por un algoritmo de optimización de saltamontes (GOA del inglés *Grasshopper Optimisation Algorithm*) inspirado en la naturaleza para la planificación de la capacidad a largo plazo de una micro-red independiente de la red. La micro-red del estudio incorpora un aerogenerador, un sistema fotovoltaico, un sistema de almacenamiento y un generador diésel. La implementación del algoritmo EMS se optimiza con GOA y se analiza la eficiencia y el rendimiento. Este EMS plantea un problema de optimización multiobjetivo que minimiza el coste energético y la deficiencia de la probabilidad de suministro energético. La simulación de micro-red a largo plazo se realiza con el GOA y se compara con la optimización de enjambre de partículas PSO y un algoritmo de búsqueda de cuco (CSA del inglés *Cuckoo Search Algorithm*) obteniendo buenos resultados. Bukar et al. [37] presentan un EMS multiobjetivo con tres funciones objetivas para minimizar el costo operativo, el costo y la confiabilidad del servicio. Se propone el algoritmo avanzado de optimización del enjambre de partículas con el que se obtiene el frente de Pareto para el despacho de energía de la micro-red. El trabajo muestra que el método avanzado de optimización de un enjambre de partículas presenta mejores resultados que los algoritmos de clasificación genética no dominados-II (NSGA-II) ampliamente utilizados en la resolución de micro-redes. El trabajo no propone una metodología para la toma de decisiones. En [38], el artículo establece un problema de optimización multiobjetivo. Los objetivos para optimizar son el coste de la energía, las emisiones de CO₂ y la gestión del sistema de almacenamiento; la optimización ayuda a realizar una planificación energética inteligente de la red. Coordinará el sistema de almacenamiento de la micro-red a través de una plataforma en la nube, el monitoreo del funcionamiento del paquete de baterías se realiza en tiempo real, el algoritmo de optimización de enjambre de partículas multiobjetivo se utiliza para resolver el problema correctamente [39].

1.6. Justificación

A pesar de que se han propuesto una gran variedad de trabajos enfocados al desarrollo de EMS en micro-redes, la mayoría de ellos únicamente abordan la determinación de la gestión energética que minimiza o reduce el costo del consumo de energía proveniente de la red eléctrica principal o la gestión apropiada de los sistemas de almacenamiento en las micro-redes de los vehículos marítimos autónomos, sin tomar en cuenta las incertidumbres que introduce la energía fotovoltaica, eólica, mareomotriz y la demanda de carga en el sistema. Bajo esa justificación, en el presente trabajo de tesis se propone el diseño y simulación de un EMS que integre optimización, MPC y métodos estocásticos para tomar en cuenta la incertidumbre antes mencionada. Para este fin, el trabajo de investigación contempla la implementación de diferentes métodos estocásticos para el manejo de incertidumbres en las fuentes de energía renovable y las cargas, además de los métodos de MPC para el diseño de EMS aplicados al modelo general de micro-red y un sistema específico de micro-red instalado en el vehículo marítimo autónomo de monitoreo de hábitos alimenticios del pez león realizado por el CICY donde se optimizará el costo de la energía. El vehículo marítimo autónomo es la base de operación de un robot submarino que estará equipado con cámaras de visión de inteligencia artificial capaz de identificar al pez león, el robot se encargará de seguir a grupos de peces león y enviar las coordenadas a buzos para comenzar su caza. El objetivo es ayudar a reducir la población de pez león en el caribe mexicano debido a que es una especie invasora que no tiene un depredador natural en el ecosistema del caribe y su población crece a tasas alarmantes, provocando un problema ecológico. Adicionalmente el EMS se implementa con un algoritmo multiobjetivo para poder tomar en cuenta variables que un problema de un solo objetivo no sería posible y entregar soluciones más realistas. El EMS será aplicado a un sistema específico para un edificio bioclimático ubicado en la Universidad de Almería España optimizando simultáneamente la emisión de CO₂ y costo de energía.

1.7. Hipótesis

La implementación de un algoritmo de EMS que integre MPC y métodos estocásticos para tomar en cuenta la intermitencia de las fuentes de energía renovable puede mejorar la gestión de la energía para micro-redes de vehículos marítimos autónomos y edificio bioclimáticos cuantificando el error cuadrático medio de las pérdidas de potencia a través de la comparación con EMSs convencionales.

1.8. Objetivo

El objetivo de este trabajo de investigación es abordar el diseño y simulación de un EMS para la optimización de la energía de una micro-red tomando en cuenta las incertidumbres y la naturaleza estocástica asociadas a la energía solar, eólica, mareomotriz y a la demanda de la carga. En este sentido, el EMS se formulará como un problema de optimización de energía, lo que permitirá evaluar la gestión óptima de la energía del sistema de almacenamiento para un horizonte de tiempo dado para cuando la micro-red instalada en el vehículo marítimo autónomo comience a funcionar. Se tomará en cuenta el modelado de los elementos de generación renovable de los convertidores de CD-CD que la componen. Para resolver el problema de optimización se considera la aplicación de métodos basados en MPC. Los siguientes puntos se desarrollarán a lo largo del trabajo de investigación:

- Análisis de las estrategias MPC existentes para EMS, a fin de desarrollar nuevas estrategias de MPC que contemplen la utilización de técnicas basadas en métodos estocásticos.
- Implementación computacional de las estrategias de MPC desarrolladas para el EMS, para evaluarlas en la Micro-red implementada en el vehículo marítimo de monitoreo de hábitos alimenticios del pez león realizado por el CICY.
- Desarrollo de modelos detallados de cada uno de los elementos que conforman la micro-red genérica, elementos de generación, convertidores CD-CD, que describan apropiadamente la respuesta eléctrica del sistema ante condiciones de operación prácticas.
- Integración de un EMS para optimizar el uso y el costo de la energía demandada por la micro-red genérica tomando en cuenta la incertidumbre asociada a las fuentes de energía solar, eólica, mareomotriz y la demanda de la carga.
- Desarrollo de algoritmo de optimización multiobjetivo para la obtención de soluciones realistas que tomen cuenta varios aspectos importantes para la toma de decisiones en los mercados eléctricos, simulándolo para una micro-red de edificio bioclimático ubicado en la Universidad de Almería España.

CAPITULO 2.

METODOLOGÍA

La metodología propuesta en este trabajo está compuesta de cuatro etapas que permiten el desarrollo del sistema de manejo de energía aplicado a un vehículo marítimo autónomo y un edificio bioclimático.

El EMS planteado en este trabajo podrá ser simulado para cualquier ciudad ya que únicamente se necesitan los datos de radiación solar o velocidad de viento de la ciudad específica. Los casos de estudio en este documento son para la Ciudad de Almería España debido a que la primera simulación realizada se desarrolló en el edificio Bioclimático de CIESOL en la Universidad de Almería utilizando datos proporcionados por el grupo de investigación de automática de CIESOL. La segunda simulación del EMS se realizó en la micro-red de un vehículo marítimo autónomo que se pondrá a funcionar en las costas de Cancún Quintana Roo con datos proporcionados por el servicio meteorológico nacional de México.

La primera etapa para la realización del EMS es la obtención de datos históricos de radiación solar y velocidad de viento, para realizar los modelos de predicción, la primera prueba se realiza con datos históricos proporcionados por el centro de investigación CIESOL de la ciudad de Almería España, las mediciones proporcionadas se realizaron con un intervalo de un minuto para realizar predicciones a 15, 30 y 60 minutos. Para los datos históricos de Cancún Quintana Roo se utilizan los datos proporcionados por el servicio meteorológico nacional de México con datos a intervalos de 30 minutos para realizar predicciones a 1 hora.

los métodos que se evalúan para realizar las predicciones de los datos meteorológicos son métodos de series de tiempo específicamente el de filtro de Kalman, doble exponencial suavizado y pronóstico persistente. Se realiza una comparación escogiendo el mejor para la predicción, desarrollamos un análisis de la raíz del error cuadrático medio (*RMSE del inglés root-mean-square error*) para la predicción de radiación solar y velocidad del viento. El método de predicción con menor RMSE se elige como el de mayor precisión y es el que se utiliza para el desarrollo del EMS.

La segunda etapa consiste en realizar los modelos matemáticos de los componentes de la micro-red, se desarrolla el modelo del sistema fotovoltaico, sistema eólico, sistema de almacenamiento, generador diésel, la red principal y los convertidores. En la tercera etapa se integra el método de predicción de radiación solar y velocidad de viento con los modelos de los

componentes de la micro-red mediante el MPC con optimización mono objetivo y multiobjetivo. El MPC mono objetivo se plantea como un problema de optimización donde la función de costo representa el costo económico de la energía de red principal y el generador diésel, el MPC multiobjetivo se plantea como un problema con dos objetivos a optimizar donde las funciones de costo son el costo de la energía y función de emisión de CO₂ al ambiente, las restricciones de igualdad a función son las ecuaciones de balance de potencia de la micro-red, las restricciones de desigualdad a función las introduce el modelo matemático del sistema de almacenamiento, las restricciones de desigualdad a variable son los límites físicos y eléctricos de los componentes de la micro-red. El problema de optimización es resuelto mediante el método de AG (Algoritmo Genético), el problema se resuelve para un horizonte de predicción de N etapas, donde solo se guarda la solución de la primera etapa y se desechan las demás, en la siguiente solución se toma de la segunda etapa en adelante hasta N+1 y de igual forma que en la anterior solo se toma la solución de la segunda etapa hasta llegar al final de las etapas del problema. El modelo del MPC explícito se detalla en la sección 3.2.

En la cuarta etapa se realizan las simulaciones de EMS integrado a varias micro-redes de prueba, la primera micro-red de prueba MCR1 está integrada al vehículo marítimo autónomo que se utiliza como base para un submarino que se encargara de monitorear el pez león en el caribe mexicano específicamente en la ciudad de Cancún Quintana Roo. La segunda y tercera micro-redes de prueba MCR2 y MCR3 están integradas a un vehículo terrestre que se utiliza en CIESOL en la Universidad de Almería España para realizar pruebas, MCR2 es una micro-red aislada y MCR3 está conectada a la red, la cuarta micro-red de prueba MCR4 está instalada para autoconsumo en el edificio de bioclimático de CIESOL dentro de la Universidad de Almería. Además, con micro-red MCR4 se realiza la implementación de una optimización multiobjetivo que minimiza la función objetivo de costo de energía y minimiza la función objetivo de emisión de CO₂, esto nos provee la ventaja de tener muchas soluciones que se pueden adaptar a diferentes circunstancias que no necesariamente necesitan un óptimo global. Se pueden tomar en cuenta soluciones que pueden tomar en cuenta factores sociales o ambientales y no únicamente económicos.

Durante el primer año de doctorado se realizó el análisis de los modelos matemáticos necesarios para el EMS del vehículo marítimo autónomo, tanto de los componentes de la micro-red como los modelos y de optimización y algunos controles necesarios. En el semestre cuatro se desarrolla el MPC para su simulación en conjunto con el modelo de con los métodos de series de tiempo para predicción de radiación solar y velocidad de viento ya desarrollado. En el

semestre cinco y seis se obtuvieron resultados para cuatro micro-redes de prueba MCR1, MCR2, MCR3 y MCR4. En el semestre 7 se escribió el documento de tesis y se implementó optimización multiobjetivo para la micro-red MCR3.

2.1. Modelado matemático

En esta sección del trabajo se desarrollaron las revisiones de los modelos matemáticos para los elementos que conformarán la micro-red, el sistema eléctrico principal y los modelos de las variables climatológicas (radiación solar y velocidad viento) para poder lograr una adecuada predicción y un acoplamiento correcto con los dispositivos eléctricos (Bus CD, Convertidores CD-CD, paneles solares, aerogenerador, generador mareomotriz y sistemas de almacenamiento banco de baterías), en las cuales se realizarán las acciones de control. De esta forma, se obtuvo un pleno conocimiento del modelo matemático completo de la micro-red, el sistema eléctrico y comportamiento de las incertidumbres climatológicas, aspecto necesario para determinar las variables sobre las cuales deberá actuar el EMS para el correcto funcionamiento de la micro-red implementada en el vehículo marítimo de monitoreo de hábitos alimenticios del pez león realizado por el CICY. Además, se agregó como caso de estudio una micro-red de tipo no autónomo conectada a la red.

2.2. Banco de baterías

Los bancos de baterías permiten almacenar energía proveniente de las fuentes de generación renovable conectadas a la micro-red. A diferencia de las fuentes de generación renovables, estos elementos pueden ser considerados como fuentes de energía despachables debido a que la energía almacenada puede ser utilizada de manera controlada. Las baterías pueden operar en modo de carga o descarga para aportar o consumir una cantidad neta de potencia activa, respectivamente, en su nodo de conexión. Esto permite manejar el nivel de energía almacenada en las mismas. Dicho nivel de energía almacenada se refleja a través del estado de carga (*SOC del inglés State of charge*). Considerando que el banco está conformado por un número j de baterías, la j -ésima batería se puede representar entonces por medio de dos fuentes de generación de potencia activa, como se ilustra en la Figura 2.1 [10]. Una de ellas representa la potencia de carga de la j -ésima batería en una etapa z del tiempo t , $P_{Bcj}^{tz} \leq 0$ y la otra la potencia de descarga de la j -ésima batería en una etapa z del tiempo t , $P_{Bdj}^{tz} \geq 0$, la suma de ambas potencias representa la potencia neta de la j -ésima batería en una etapa z del tiempo t que pertenece a un conjunto de etapas T , P_{Bnj}^{tz} aportada o consumida por la batería en su

nodo de conexión,

$$P_{Bnj}^{t_z} = P_{Bcj}^{t_z} + P_{Bdj}^{t_z} ; 0 \leq P_{Bdj}^{t_z} ; P_{Bcj}^{t_z} \leq 0; \quad \forall t_z \in T \quad (1)$$

En la ecuación (1) los subíndices Bnj, Bcj y Bdj representan parámetro de batería nominal, parámetro de carga de batería y parámetro de descarga de batería respectivamente. Los superíndices t_z representa la etapa de tiempo numero z.

En adición, el voltaje en el nodo de conexión se representa por su magnitud $V_{j-esima}^{t_z}$. Así, las variables de decisión de la j -ésima batería son $[P_{Bcj}^{t_z}, P_{Bdj}^{t_z}] \in y_B \forall t_z \in t$, mientras que $[V_j^{t_z}, I_j^{t_z}] \in y_R \forall t_z \in t$. Donde y_R es el conjunto de variables de decisión de red, y_B es el conjunto de variables de decisión de las baterías y t_z representa la etapa de tiempo z.

Además, el estado de carga de la j -ésima batería en el instante t_z , $SOC_{Bj}^{t_z}$ se puede aproximar por medio de ecuación (2). $SOC_{Bj}^{t_z}$

$$SOC_{Bj}^{t_z} = SOC_{Bj}^{t_0} - \frac{\varepsilon_{cj} \Delta t}{E_{Bnomj}} \sum_{t=1}^{t_z} P_{Bcj}^t - \frac{\Delta t}{E_{Bnomj} \varepsilon_{dj}} \sum_{t=1}^{t_z} P_{Bdj}^t \quad (2)$$

Donde ε_{cj} representa el coeficiente de eficiencia de carga, ε_{dj} representa el coeficiente de eficiencia de descarga, E_{Bnomj} representa la capacidad de almacenaje, Δt es el cambio en el tiempo y $SOC_{Bj}^{t_0}$ el porcentaje de carga inicial de la batería. Se hace notar que se asume que la energía aportada por las baterías tiene un costo alto de mantenimiento, puesto que es absorbida y aportada en el mismo nodo de conexión. Sin embargo, en ausencia de un mecanismo de respuesta a la demanda y de otras fuentes despachables, las baterías son un elemento primordial para el manejo óptimo de la energía de la micro-red del vehículo marítimo. Esto debido a que pueden ser cargadas o descargadas en periodos que maximizan el beneficio económico global, lo cual debe ser determinado por medio del algoritmo de optimización.




Figura 2.1. Esquema representativo de un banco de batería [10]

2.3. Aerogeneradores Tidal

Para fines de análisis el aerogenerador puede considerarse como una fuente controlada de potencia activa $P_{A_j}^{t_z}$, dependiente únicamente de la velocidad del viento $S_w^{t_z}$, densidad del aire δ y el área cubierta por las palas de la turbina de viento A , [40].

$$P_{A_j}^{t_z} = \delta A (S_w^{t_z})^3 / 2; \forall t_z \in T \quad (3)$$

Se evalúa la aportación de potencia del nodo j -th aerogenerador para una curva de velocidad de viento $S_w^{t_z} \forall t_z \in T$, densidad δ y área A dados. La magnitud $V_j^{t_z}$ y corriente $I_j^{t_z}$ del nodo de conexión son considerados como variables de decisión, tal que $[V_j^{t_z}] \in \mathcal{Y}_R$ donde \mathcal{Y}_R se refiere a las variables de decisión de la red. Se toma en cuenta el costo de operación de mantenimiento del aerogenerador debido a que en las energías renovables el gasto mas importante para la operación es el mantenimiento de los equipos electromecánicos y electrónicos. Además, se considera disponible un buen pronóstico de las curvas de velocidad de viento mediante métodos estocásticos.

2.4. Módulos fotovoltaicos

La Figura 2.2 muestra el modelo esquemático de un módulo fotovoltaico conectado al nodo k -th a través de un convertidor de CD-CD [41]. La expresión implícita (4) modela el comportamiento de la corriente de CD en las terminales del panel $I_{CD_k}^{t_z}$. Donde I_{ph} , I_0 , $V_{CD_k}^{t_z}$, R_S , n_s y n_p representan la corriente del panel fotovoltaico, la corriente de saturación, el voltaje de CD en las terminales del módulo, la resistencia en serie, el número de celdas en serie y paralelo, respectivamente. El término R_S se evalúa a partir de (5), donde V_{oc} , V_{mp} , I_{sc} , I_{mp} representan el voltaje de circuito abierto, voltaje del punto de máxima potencia, corriente de corto circuito y la corriente del punto de máxima potencia, respectivamente. Los términos I_{sc} y V_{oc} se evalúan a partir de (6) y (7),

respectivamente. Donde $I_{sc,sc}$, G , G_{sc} , k_i , T , T_{sc} , $V_{oc,sc}$ y k_v representan la corriente de corto circuito estándar bajo condiciones de prueba, irradiancia, irradiancia bajo condiciones de prueba, coeficiente de temperatura de corriente, temperatura del panel, temperatura estándar bajo condiciones de prueba, tensión de circuito abierto estándar bajo condiciones de prueba y coeficiente de temperatura de tensión, respectivamente.




Figura 2.2. Modelo esquemático de un módulo fotovoltaico [33]

$$I_{CDk}^{t_z} = \left[I_{ph} - I_0 \left(\exp \left(\frac{\frac{V_{CDk}^{t_z}}{n_s} + \frac{I_{CDk}^{t_z} R_s}{n_p}}{V_{CD}^{t_z}} \right) - 1 \right) \right] n_p; \forall t_z \in T \quad (4)$$

$$R_s = \frac{\frac{V_{oc} - V_{mp}}{n_s} + V_{CD}^{t_z} \ln \left(\frac{I_{sc} - I_{mp}}{I_{sc}} \right)}{\frac{I_{mp}}{n_p}} \quad (5)$$

$$I_{sc}(T, G) = I_{sc,sc} - \frac{G}{G_{sc}} \left[1 + \frac{k_i}{100} (T - T_{sc}) \right] \quad (6)$$

$$V_{oc}(T) = V_{oc,sc} \left[1 + \frac{k_v}{100} (T - T_{sc}) \right] \quad (7)$$

En este trabajo, los parámetros del módulo fotovoltaico involucrados en (4)-(7) se tomaron con base en la hoja de datos del módulo monocristalino SLA-M [42] marca SILFAB SOLAR. Además, se considera disponible un buen pronóstico de las curvas de irradiación solar mediante métodos estocásticos. Las curvas de irradiación solar consideradas en este trabajo se

proporcionan en el anexo 1.

De acuerdo con el modelo de la Figura 2.2, la potencia inyectada en las terminales de CD (generada por el módulo) puede expresarse directamente por (8). Además, también se debe satisfacer el balance de potencia entre las terminales del bus CD y de los convertidores, si se desprecian las pérdidas del convertidor, este balance se representa por ecuación (9).

$$P_{CDk}^{t_z} \left(V_{CDk}^{t_z}, I_{CDk}^{t_z} \right) = I_{CDk}^{t_z} V_{CDk}^{t_z}, \forall t_z \in T \quad (8)$$

$$P_{CDk+1}^{t_z} \left(V_k^{t_z}, V_m^{t_z}, I_k^{t_z}, I_m^{t_z} \right) = P_{CDk}^{t_z} \left(V_{CDk}^{t_z}, I_{CDk}^{t_z} \right); \quad (9)$$

Para el caso de los módulos fotovoltaicos las variables de decisión introducidas son $\left[V_{CDk}^{t_z}, I_{CDk}^{t_z} \right] \in y_{MF} \left(\forall t_z \notin T \right)$, donde y_{MF} representa los límites físicos de máximos y mínimos del módulo fotovoltaico.

2.5. Cargas eléctricas

El consumo de energía en los nodos de carga de la micro-red se representa por medio de un modelo de potencia constante para todo el intervalo T. La potencia activa $P_{li}^{t_z}$ consumida en el instante t_z y nodo i se representa entonces por ecuación (10). Donde $P_{li}^{t_z}$ representan el consumo de potencia activa en dicho nodo en el instante t_z respectivamente.

$$P_{li}^{t_z} \forall t_z \in T \quad (10)$$

El modelo de demanda de energía no introduce variables de decisión al problema de optimización, pero la magnitud $V_i^{t_z}$ del nodo de conexión sí es considerado como variable de decisión, tal que $\left[V_i^{t_z}, I_i^{t_z} \right] \in y_R \left(\forall t_z \in T \right)$. Además, se considera que se dispone de un buen pronóstico estocástico de las curvas de demanda de potencia $\left(P_{li}^{t_z} \forall t_z \notin T \right)$.

2.6. Convertidores CD-CD de potencia

Los convertidores necesarios para el proyecto son del tipo Buck-boost bidireccionales y Buck-boost normales. En este trabajo analizaremos el modelo matemático en espacio de estados para comprobar el comportamiento dinámico.

Se han modelado estos sistemas con diversas técnicas, una de ellas como se muestra en las

Figura 2.3 y Figura 2.4, utilizando el esquema eléctrico y circuito equivalente eléctrico, de esta manera se pueden aplicar las Leyes de corrientes y voltajes de Kirchoff obteniendo un conjunto de ecuaciones que describen el comportamiento del sistema[43].

La representación en el espacio de estados promedio se emplea para modelar el convertidor bukc-boost bidireccional.




Figura 2.3. Convertidores Buck-boost bidireccionales simplificado [35]

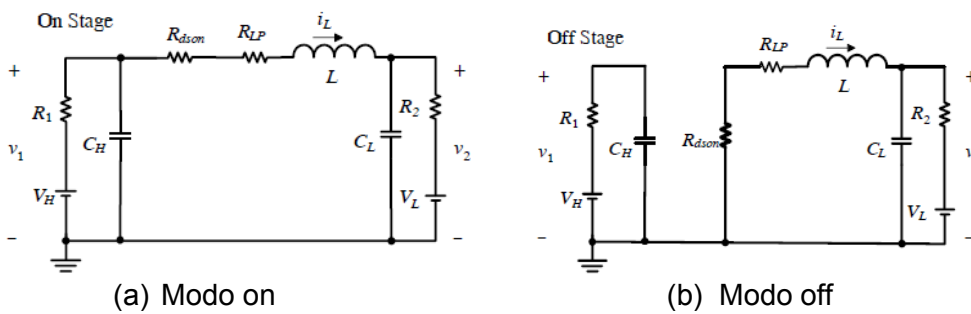


Figura 2.4. Equivalente eléctrico de convertidor CD-CD bidireccional [35]

El modelado dinámico de los convertidores se ha estudiado con la representación en espacio de estados como en (11) y (12), donde se analizan los circuitos con las leyes de voltajes y corrientes de Kirchoff, para generar un conjunto de ecuaciones que describirán el comportamiento del sistema [44] [27][45], se seleccionan los estados de interés, las entradas y las salidas, y se agrupan en una forma general de matrices como se ve en las ecuaciones (13) y (14).

$$dX=AX+Bu \tag{11}$$

$$Y=CX+Du \tag{12}$$

El modelo de espacio de estado en estado estacionario se muestra en las siguientes expresiones:

$$0=A \cdot \begin{bmatrix} i_L \\ v_1 \\ v_2 \end{bmatrix} + B \cdot \begin{bmatrix} V_L \\ V_H \end{bmatrix} \quad (13)$$

Donde

$$A = \begin{bmatrix} \frac{R_p}{L} & \frac{D}{L} & \frac{1}{L} \\ \frac{D}{C_H} & \frac{-1}{R_1 C_H} & 0 \\ \frac{1}{C_L} & 0 & \frac{1}{R_2 C_L} \end{bmatrix} \quad B = \begin{bmatrix} 0 & 0 \\ 0 & \frac{1}{R_1 C_H} \\ \frac{1}{R_1 C_H} & 0 \end{bmatrix} \quad (14)$$

El modelo de espacio de estado promedio es mostrado

$$\frac{d}{dt} \begin{bmatrix} \hat{i}_L \\ \hat{v}_1 \\ \hat{v}_2 \end{bmatrix} = A \cdot \begin{bmatrix} \hat{i}_L \\ \hat{v}_1 \\ \hat{v}_2 \end{bmatrix} + B \cdot \begin{bmatrix} I_L \\ V_1 \\ V_2 \end{bmatrix} \hat{d} \quad (15)$$

Donde

$$C = \begin{bmatrix} 0 & \frac{1}{L} & 0 \\ \frac{1}{C_H} & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (16)$$

Resolviendo, se obtiene la siguiente solución

$$\frac{\hat{v}_1}{d} = \frac{\frac{D}{C_H} \cdot \frac{\hat{i}_L}{d} - \frac{1}{C_H} \cdot I_L}{s + \frac{1}{C_H R_1}} \quad (17)$$

$$\frac{\hat{v}_2}{d} = \frac{\frac{1}{C_L} \cdot \frac{\hat{i}_L}{d}}{s + \frac{1}{C_L R_2}} \quad (18)$$

$$\frac{\hat{i}_L}{d} = \frac{(as+1)[(bs+1)V_1 - c]}{(Ls+R_p)(as+1)(bs+1) + D^2 R_1 (as+1) + R_2 (bs+1)} \quad (19)$$

Donde

$$a = C_L R_2, b = C_H R_1, c = D I_L R_1.$$

También se analiza el modelo del convertidor Buck-boost normal en el cual se comienza con el análisis del circuito. Al igual que el caso anterior utilizamos las ecuaciones (11) y (12) realizando el análisis de las leyes de Kirchoff agrupándolas en matrices como se muestra en las

ecuaciones (20), (21), y (22)




Figura 2.5. Convertidores Buck-boost simplificado [35]

$$A = \begin{bmatrix} 0 & \frac{D-1}{L} \\ \frac{1-D}{C} & -\frac{1}{RC} \end{bmatrix} \quad (20)$$

$$B = \begin{bmatrix} \frac{D}{L} \\ 0 \end{bmatrix} \quad (21)$$

$$C = [0 \ 1] \quad (22)$$

Resolviendo (20), (21) y (22) se obtiene

$$G(s) = \frac{K_e * \frac{1}{RC}}{s^2 + \frac{1}{RC}s + \frac{(1-D)^2}{LC}} \quad (23)$$

2.7. Radiación solar

La radiación solar incidente sobre el panel es modelizada para tener una mejor estimación de la producción de energía del panel fotovoltaico para que el EMS realice una optimización correcta. La radiación es un parámetro que depende de muchas variables, tanto temporales como de posición, por tanto, su modelización es algo más compleja que el modelo del panel.

Para modelizar la radiación solar incidente se tendrá que caracterizar a partir de las ecuaciones que rigen el comportamiento de la radiación en una superficie inclinada, hay muchos tipos de modelos para caracterizar el comportamiento de la radiación, se indicará en cada caso de aplicación el modelo utilizado [46]. Para esto se debe calcular la excentricidad ϵ_0 , la declinación solar δ , descritas en las ecuaciones (24) y (25) respectivamente. Además, calcularemos el ángulo horario ω , el ángulo o distancia cenital θ_{zs} expresada en (27).

$$\varepsilon_0 = 1 + 0.033 \cos\left(\frac{360dn}{365}\right) \quad (24)$$

$$\delta = 23.45 \operatorname{sen}\left(360\frac{284+dn}{365}\right) \quad (25)$$

dn = Día del año, entre 1 a 365

$$\omega = (12 - \text{Hora}) * 15 \quad (26)$$

$$\vartheta_{zs} = \cos^{-1}(\operatorname{sen}\delta \operatorname{sen}\phi + \cos\delta \operatorname{sen}\omega) \quad (27)$$

ϕ es la latitud del lugar donde se encuentra el panel solar.

La ecuación (29) corresponde al coseno de ángulo de incidencia que corresponde al ángulo entre la normal y la superficie y el vector sol-tierra. Este ángulo se hace necesario para el cálculo de radiación en los casos de superficies con movimiento arbitrario, como el caso del panel colocado en lo alto del techo del vehículo autónomo marítimo.

$$\begin{aligned} \cos\vartheta_s = & \operatorname{sen}\delta \operatorname{sen}\phi \cos\beta - \operatorname{sen}\delta \cos\phi \operatorname{sen}\beta \cos\alpha + \cos\delta \cos\phi \cos\beta \cos\omega + \cos\delta \cos\phi \cos\beta \cos\omega \\ & + \cos\delta \operatorname{sen}\alpha \operatorname{sen}\omega \operatorname{sen}\beta \end{aligned} \quad (29)$$

Los únicos términos que no conocemos de la anterior expresión son α y β que son ángulos que definen la orientación de la inclinación del panel solar respectivamente.

Teniendo clara la definición de ángulo cenital y su expresión, la expresión anterior se puede reducir.

$$\begin{aligned} \cos\vartheta_s = & \cos\beta \cos\vartheta_{zs} - \operatorname{sen}\delta \cos\phi \operatorname{sen}\beta \cos\alpha + \cos\delta \cos\phi \cos\beta \cos\omega + \cos\delta \cos\phi \cos\beta \cos\omega \\ & + \cos\delta \operatorname{sen}\alpha \operatorname{sen}\omega \operatorname{sen}\beta \end{aligned} \quad (30)$$

Irradiancia extraterrestre sobre superficie inclinada: Es la cantidad de irradiancia que recibirá la superficie horizontal en condiciones ideales.

$$B_0(0) = B_0 \varepsilon_0 \cos\vartheta_{zs} \quad (31)$$

Donde ε_0 es la excentricidad solar, B_0 constante solar que representa la irradiancia que alcanza la tierra y tiene un valor de 1367 W/m² [46].

La irradiancia global sobre una superficie arbitrariamente orientada e inclinada es calculada con las componentes de irradiancia directa sobre plano inclinado, difusa y reflejada como se muestra en la ecuación (32).

$$G(\alpha, \beta) = B(\alpha, \beta) + D(\alpha, \beta) + R(\alpha, \beta) \quad (32)$$

Donde

B es la radiación directa sobre superficie arbitrariamente orientada e inclinada

D es la radiación difusa sobre superficie arbitrariamente orientada e inclinada

R es la radiación reflejada sobre superficie arbitrariamente orientada e inclinada

Radiación directa sobre superficie arbitrariamente orientada e inclinada: es calculada a través de la radiación directa medida sobre superficie horizontal $B(0)$ y los términos geométricos definidos anteriormente.

$$B(\alpha, \beta) = B(0) \frac{\cos \theta_s}{\cos \theta_{zs}} \quad (32)$$

Radiación reflejada sobre superficie arbitrariamente orientada e inclinada, es calculada a través de la radiación reflejada medida sobre superficie horizontal $G(0)$ y los términos geométricos definidos anteriormente.

$$R(\alpha, \beta) = G(0) \rho \left(\frac{1 - \cos \beta}{2} \right) \quad (33)$$

Radiación difusa sobre superficie arbitrariamente orientada e inclinada es calculada a través de la radiación reflejada medida sobre superficie horizontal $D(0)$ y los términos geométricos definidos anteriormente.

$$D(\alpha, \beta) = D(0) \left(\frac{1 - \cos \beta}{2} \right) (1 - A_i) + D(0) A_i \frac{\cos \theta_s}{\cos \theta_{zs}} \quad (34)$$

El modelo geométrico de radiación solar nos da un valor preciso de la radiación que incide en la superficie del panel fotovoltaico, lo cual es necesario para tener mejores predicciones de potencia producida por un sistema fotovoltaico que proporciona una entrada precisa al MPC para que el control sea eficiente en el EMS.

2.8. Métodos de series de tiempo para estimación de incertidumbres

Una serie de tiempo es una secuencia ordenada de valores de una variable a intervalos de tiempo igualmente espaciados. La variable puede ser la temperatura del agua de un lago, la radiación solar, la velocidad de viento, la concentración de una sustancia, la fuerza de un flujo, el tamaño de una población, etc. Esta sección describe brevemente los métodos de series de tiempo seleccionados en este trabajo.

2.8.1. Método de Doble Exponencial Suavizado

El doble exponencial suavizado (DES) proporciona un promedio móvil de todos los valores observados con anterioridad con dos pesos exponenciales, con frecuencia el método es apropiado para datos que no tienen una tendencia predecible hacia arriba o hacia abajo, el método revisa continuamente el valor estimado a la luz de experiencias recientes. Este método se basa en promediar (suavizar) los valores pasados de una serie en forma exponencial decreciente.

Este método utiliza datos de listas cronológicas de las variables. El primer paso de este método es calcular el valor atenuado u ordenada en el origen S_t representado en la ecuación (35). Algunos métodos de series de tiempo no se destacan por el seguimiento de los datos cuando hay una tendencia. el método de DES mejora esta situación mediante la introducción de una segunda ecuación (36) que calcula en la tendencia del periodo de datos b_t con una segunda constante γ que representa la constante de atenuación de estimación de tendencia de los datos, que debe elegirse junto con α que representa la constante de atenuación de promedio de los datos [21].

$$S_t = \alpha y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \text{ donde } 0 \leq \alpha \leq 1 \quad (35)$$

$$b_t = \gamma(S_t + S_{t-1}) + (1 - \gamma)b_{t-1} \text{ donde } 0 \leq \gamma \leq 1 \quad (36)$$

Se debe de tener en cuenta que el valor actual y_t de la serie se utiliza para calcular su reemplazo de valor suavizado [44].

hay una variedad de esquemas para establecer valores iniciales para b_t en el método de DES como lo vemos en la ecuación (37).

$$b_1 = y_2 - y_1$$
$$b_1 = \frac{1}{3}[(y_2 - y_1) + (y_3 - y_2) + (y_4 - y_3)] \quad (37)$$

$$F_{t+k} = S_t + b_t \quad (38)$$

La ecuación (38) calcula el pronóstico F_{t+k} de la variable medida sumando el valor atenuado y la tendencia del periodo de datos.

2.8.2. Método de Filtro de Kalman

El filtro de Kalman es un conjunto de ecuaciones matemáticas que proporciona un medio computacional (recursivo) eficiente para estimar el estado de un proceso, de manera que minimiza la media del error al cuadrado. El filtro es muy poderoso en varios aspectos: admite estimaciones de estados pasados, presentes e incluso futuros, y puede hacerlo incluso cuando se desconoce la naturaleza precisa del sistema modelado [48].

El filtro de Kalman aborda el problema general de tratar de estimar el estado $x \in \mathfrak{R}^n$ de un proceso controlado de tiempo discreto que se rige por la ecuación en diferencias estocásticas lineal.

$$x_k = Ax_{k-1} + Bu_{k-1} + w_{k-1} \quad (39)$$

con una medida $z \in \mathfrak{R}^m$ que es.

$$z_k = Hx_k + v_k \quad (40)$$

Las variables aleatorias w_k y v_k representan el proceso y el ruido de medición (respectivamente). Se supone que son independientes, blancas y con distribuciones de probabilidad normales.

$$p(w) = N(0, Q), \quad (41)$$

$$p(v) = N(0, R), \quad (42)$$

En la práctica, la matriz de covarianza de ruido de proceso Q y las matrices de covarianza de ruido de medición R pueden cambiar con cada paso de tiempo o medición, sin embargo, aquí asumimos que son constantes.

La $n \times n$ matriz A en la ecuación de diferencia (39) relaciona el estado en el paso de tiempo anterior $k-1$ al estado en el paso actual k en ausencia de una función de conducción o ruido de proceso. Nota que en la práctica la matriz A puede cambiar con cada paso de tiempo, pero aquí asumimos que es constante. La $n \times 1$ matriz B relaciona la entrada de control opcional $u \in \mathfrak{R}^l$ al estado x . La matriz H de dimensión $m \times n$ en la ecuación (40) relaciona el estado con la medición z_k . En la práctica, podría cambiar H con cada paso de tiempo o medición, pero aquí asumimos que es constante.

2.8.3. Modelo de pronóstico persistente

El modelo de pronóstico persistente (*PSS del inglés Persistent Skill Scores*) supone que los valores de irradiancia solar y velocidad de viento en el próximo período de tiempo son los mismos que el anterior [49].

$$y^{k+1} = y^k \quad (43)$$

En otras palabras, el modelo PSS supone que las predicciones futuras son iguales a los datos medidos actuales. De la ecuación (43), los problemas de este modelo es el retraso entre el tiempo de pronóstico y la observación. Este retraso se ilustra en la Figura 2.6.

Para el pronóstico a corto plazo, debido al cambio lento del clima, PSS funciona muy bien. Si un modelo de pronóstico puede superar a PSS, ese modelo se considera bueno.

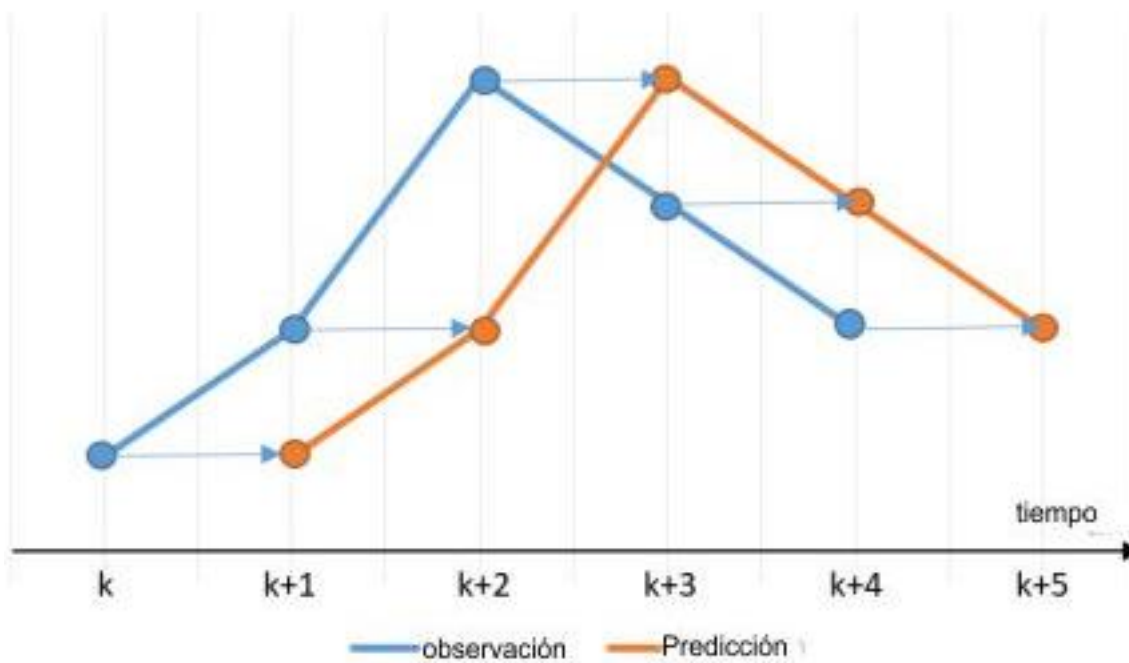


Figura 2.6. Modelo de pronóstico persistente [39]

En este trabajo los tres métodos son comparados para poder definir el mejor comportamiento en la predicción de radiación solar y velocidad de viento. La comparación se realiza en la sección 4.2. de resultados donde se realiza un análisis estadístico a través de error cuadrático medio (RMSE de las ingles *root-mean-square error*).

CAPITULO 3.

MODELO GENÉRICO DE OPTIMIZACIÓN PARA MICRO-REDES

Considerando conocido el pronóstico mediante técnicas estocásticas y series de tiempo de las curvas de demanda eléctrica, irradiación solar y velocidad de viento para un intervalo de tiempo T, el modelo general de optimización para micro-redes puede ser descrito por medio del modelo (35)-(38). Debe notarse que, en este modelo, se considera que el periodo de tiempo T está dado en forma discreta y compuesto por un conjunto de etapas de tiempo, tal que $t = [t_1, \dots, t_{end}]$.

$$\text{Minimización } F_T = \sum_{t_z=1}^{t_{end}} f^{t_z}(\mathbf{y}^{t_z}) \quad (35)$$

$$\text{sujeto a } \mathbf{h}^{t_z}(\mathbf{y}^{t_z}) = \mathbf{0} ; \forall t_z \in T \quad (36)$$

$$\mathbf{g}^{t_z}(\mathbf{y}^{t_z}) \leq \mathbf{0} ; \forall t_z \in T \quad (37)$$

$$\underline{\mathbf{y}} \leq \mathbf{y}^{t_z} \leq \bar{\mathbf{y}} ; \forall t_z \in T \quad (38)$$

donde tomando en cuenta que t_z representa la z -th etapa de tiempo, la descripción de los términos del modelo (35)-(38) es como sigue: F_T es la función objetivo a optimizar a lo largo del intervalo t. f^{t_z} representa la función de costo de potencia de las fuentes de potencia, $\mathbf{h}(\mathbf{y})$ es el conjunto de restricciones de igualdad que representa las ecuaciones de balance de potencia activa en todos los nodos de la micro-red (balance energético), así como otras condiciones de operación que se deben satisfacer incondicionalmente en la operación de la micro-red. $\mathbf{g}(\mathbf{y})$ es un conjunto de restricciones de desigualdad a funciones y representan los límites físicos y operativos de los elementos que componen la micro-red. \mathbf{y} es el conjunto de variables de decisión (a determinar resolviendo el modelo de optimización); compuesto por los subconjuntos \mathbf{y}_{MF} and \mathbf{y}_B , tal que $\mathbf{y} = [\mathbf{y}_{MF}, \mathbf{y}_B]$. Donde \mathbf{y}_B y \mathbf{y}_{MF} representan las variables de decisión relacionadas con las baterías de los sistemas de almacenamiento y módulos fotovoltaicos, respectivamente. El límite superior $\bar{\mathbf{y}}$ e inferior $\underline{\mathbf{y}}$ de estas variables se formulan por medio de las restricciones de desigualdad a variable (38).

3.1. Modelo explícito de optimización para micro-redes

Los modelos de los componentes de la micro-red del vehículo marítimo descritos en las secciones previas se consideran en esta sección para formular el modelo explícito de optimización. Para este fin se considera una micro-red general compuesta de una cantidad de N_{BCD} nodos en CD, N_B baterías, N_A aerogeneradores, N_{MF} módulos fotovoltaicos y N_{CE} cargas eléctricas.

3.1.1. Función Objetivo Mono objetivo

Se pretende minimizar el costo total de la energía y gestionar de forma óptima la energía del sistema de almacenamiento para abastecer el consumo energético de la micro-red del vehículo marítimo para un día en adelante. Con base en la ecuación (35), dicha función objetivo se formula de manera explícita por medio de la siguiente función,

$$F_T = \sum_{t_z=1}^{t_{end}} \sum_{j=1}^{N=10} a_j + b_j (P_{RPj}^{t_z}) + c_j (P_{RPj}^{t_z})^2 \quad (39)$$

Note que (39) denota que el objetivo a minimizar es el costo de la energía total generada por las fuentes renovables y el manejo adecuado del sistema de almacenamiento a lo largo del periodo de tiempo T para abastecer las curvas de demanda pronosticadas mediante métodos estocásticos $S_{ii}^{t_z} \forall i, t_z \in T$. Claramente el costo de operación de la energía de las fuentes renovables es el mismo para todas, el costo de la energía del sistema de almacenamiento es el más alto para el modelo de optimización, permitiendo con esto que todas las fuentes de generación alimenten tanto a los motores eléctricos como la carga del sistema de almacenamiento y cuando las fuentes renovables no sean capaces de alimentar los motores como última opción utilice la energía del sistema de almacenamiento.

Para tener en cuenta la incertidumbre que introduce la energía fotovoltaica, energía eólica y la carga se redefine la función objetivo donde se introduce un término por cada elemento como perturbación, estas se deben principalmente a entradas de datos meteorológicos. Las perturbaciones pueden ser descompuestas en una predicción normal y predicción de incertidumbre [50].

$$\bar{v}_{t_z} + \bar{w}_{t_z}, (\forall i, t_z \in T) \quad (40)$$

Donde \bar{v}_{t_z} es la perturbación actual sobre el sistema en un t_z , $\bar{v}_{t_z} = [p_{t_z}^{PV}, p_{t_z}^{Wind}, p_{t_z}^{Load}]$ es la potencia de predicción y $\bar{w}_{t_z} = [w_{t_z}^{PV}, w_{t_z}^{Wind}, w_{t_z}^{Load}]$ es la predicción de la incertidumbre asumiendo una distribución gaussiana $w = N(0, \sigma^2)$.

$$F_T = \sum_{t_z=1}^{t_{end}} \sum_{j=1}^{N=10} a_j + b_j (P_{RPj}^{t_z}) + c_j (P_{RPj}^{t_z})^2 + v_j^{t_z} + w_j^{t_z} \quad (41)$$

w_{t_z} es asumido como ruido blanco para todo t_z la predicción de la incertidumbre no afectaría la función objetivo.

3.1.2. Funciones Objetivo Multiobjetivo

En el problema de optimización multiobjetivo, se optimiza un vector de funciones objetivo, las funciones objetivo definen las características del sistema que deben mejorar. Este trabajo describe el costo de la energía a través de la ecuación de costo de energía escrita en la primera parte de la ecuación (42) y una segunda ecuación de optimización que describe el costo ecológico escrita en la segunda parte de la ecuación (42). Las restricciones representan limitaciones relativas a la solución del problema de optimización. Entonces, estas restricciones significan información que involucra variables del diseño y operación de la microrred, limitaciones físicas, seguridad, aspectos ambientales y económicos, entre otros. A continuación, se muestra el desarrollo matemático del modelo de micro-red, planteado como un problema de optimización biobjetivo [51].

$$F(f_1(x_1), f_2(x_2)) = \begin{cases} \sum_{t_z=1}^{t_{end}} \sum_{j=1}^{N=10} a_j + b_j (P_{RPj}^{t_z}) + c_j (P_{RPj}^{t_z})^2 + v_j^{t_z} + w_j^{t_z} \\ \sum_{t_z=1}^{t_{end}} \sum_{j=1}^{N=10} \chi_{ej} (P_{RPj}^{t_z}) + \chi_{\mu j} (f_{\mu}) + v_j^{t_z} + w_j^{t_z} \end{cases} \quad (42)$$

En el problema del bi-objetivo, el primer objetivo del despacho es el costo de energía calculado en base al costo del combustible gastado para generar electricidad utilizando las fuentes distribuidas presentes en la micro-red y el costo de mantenimiento. Se supone que las fuentes de energía renovable como la solar y la eólica tienen costos operativos de combustible cero, pero se incluye el costo de mantenimiento. La función de costo para el problema de optimización se muestra en la ecuación (42). donde a, b y c son los coeficientes de coste de

generación en € / kWh, y P_{RP} son las potencias de salida de generación en kWh [52].

El segundo objetivo es minimizar las emisiones debidas a los combustibles fósiles utilizados en la red principal para la generación de energía. Los equivalentes de CO₂ se utilizan para los generadores tradicionales y la generación diésel. Las emisiones de parte del sistema fotovoltaico, la turbina eólica y las baterías se consideran cero. Los multiplicadores del factor de emisión y la ecuación de la función objetivo se dan en la ecuación (42) χ_e es el factor de emisión para la red principal, χ_μ es el vector de factores de emisión para cada componente de la micro-red que consiste en un generador diésel, el sistema solar, el sistema eólico y las baterías. Según la Agencia de Protección Ambiental (EPA), los valores del factor de emisión son los límites superiores de las emisiones de CO₂ [53].

3.1.3. Restricciones de igualdad

El conjunto de restricciones de igualdad $h(\mathbf{y})$ en (36) se expresa de manera explícita por medio de las restricciones (43), las cuales se describen a continuación. Las restricciones de balance de potencia activa $\Delta P_{RD_i}^{t_z}$ correspondientes a los nodos en CD de la micro-red se expresan por medio del primer bloque en (43). Donde el límite inferior $\forall j \in i$ significa todo elemento j -th conectado al nodo i -th. Por ejemplo, el término $\sum_{\forall j \in i} \Delta P_{A_i}^{t_z}$ indica la suma de las potencias activas aportadas (generadas) por todos los aerogeneradores conectados al nodo i . Se debe aclarar que el término $\sum_{\forall j \in i | j \in N_{AI}} \Delta P_{in}^{t_z}$ indica la suma de las potencias activas inyectadas al nodo i a través de todas las terminales conectadas a dicho nodo. A partir de (8) y (9) se formulan las restricciones que modelan el comportamiento discreto por etapa de cada batería y de su correspondiente convertidor CD-CD, como se muestra en el bloque inferior de (43). Donde $P_{CD}(V, I)$ representa el término en el segundo miembro de (9). Note que (43) se formula para $(\forall t_z \in T)$.

$$\mathbf{h}^{t_z}(\mathbf{y}^{t_z}) = \left\{ \begin{array}{l} \Delta P_{RD i}^{t_z} = P_{RP i}^{t_z} + \sum_{\forall j \in i} P_{Bc j}^{t_z} + \sum_{\forall j \in i} P_{Bd j}^{t_z} + \sum_{\forall j \in i} P_{Aj}^{t_z} + \\ \sum_{\forall j \in i} P_{CD j}^{t_z} - \sum_{\forall j \in i} P_{lj}^{t_z} - \sum_{\forall j \in i | j \in N_{Al}, N_T} P_{inj j}^{t_z}(\mathbf{V}, \mathbf{I}) = 0, \\ i=1, 2, \dots, N_{bAC}; k=1, 2, \dots, N_{bAC} | \forall k \notin N_{GEN} \\ \Delta I_{CD k}^{t_z} = I_{CD k}^{t_z} - f_{CD}(V_{CD k}^{t_z}, I_{CD k}^{t_z}) = 0, \\ \Delta P_{CD k}^{t_z} = P_{CD k}^{t_z}(\mathbf{V}, \mathbf{I}) - P_{CD k}^{t_z}(V_{CD k}^{t_z}, I_{CD k}^{t_z}) = 0, \\ \Delta V_{CD k}^{t_z} = V_{CD k}^{t_z} - (\pi/16)V_k^{t_z} = 0 \\ k = N_{bDC} + 1, \dots, N_{bDC} \end{array} \right\} \quad \forall t_z \in T \quad (43)$$

3.1.4. Restricciones de desigualdad a funciones

Las únicas restricciones de desigualdad a funciones $\mathbf{g}(\mathbf{y})$ en (37) corresponden a las baterías. Las baterías tienen capacidad de carga y descarga finita. Teniendo esto en mente, el SOC se modula a lo largo del periodo de tiempo T por medio del primer bloque de (44) [10]. Donde $SOC_{Bj}^{t_0}$ es el estado inicial de carga (en t_0), la longitud de cada etapa de tiempo Δt se calcula como la resta de dos instantes consecutivos, i.e, $\Delta t = t_x - t_{x-1}$, ε_{cj} y ε_{dj} representan la eficiencia de carga y descarga, cuya capacidad nominal es $E_{Bnom j}$. Los límites superior e inferior del estado de carga son SOC_{Bj}^{\max} y SOC_{Bj}^{\min} , respectivamente.

$$\mathbf{g}^{t_z}(\mathbf{y}^{t_z}) = \left\{ SOC_{Bj}^{\min} \leq SOC_{Bj}^{t_z} \leq SOC_{Bj}^{\max} \right\} \quad \forall j \in N_B, \forall t_z \in T \quad (44)$$

3.1.5. Restricciones de desigualdad a variables

Se debe tomar en cuenta que las variables de decisión deben adquirir valores admisibles, de otra forma, la solución proporcionada por el modelo de optimización podría no tener sentido desde un punto de vista práctico. Por tal razón, las variables de decisión \mathbf{y} se limitan a lo largo del intervalo de tiempo T por medio del conjunto de restricciones (45).

$$\left\{ \begin{array}{l} \underline{\mathbf{y}}_{RD} \leq \mathbf{y}_{RD}^{t_z} \leq \bar{\mathbf{y}}_{RD} \\ \underline{\mathbf{y}}_{MF} \leq \mathbf{y}_{MF}^{t_z} \leq \bar{\mathbf{y}}_{MF} \\ \underline{\mathbf{y}}_B \leq \mathbf{y}_B^{t_z} \leq \bar{\mathbf{y}}_B \end{array} \right\} \quad \forall t_z \in T \quad (45)$$

Donde de manera explícita el conjunto de variables de decisión asociadas a la red de distribución está dado por la magnitud del voltaje y la corriente en cada nodo de la misma, así

como de las potencias activas intercambiadas con el sistema del almacenamiento, tal que $y_{RD}=[V \in V_j^{t_z}, I \in I_j^{t_z}, P_{RPj}^{t_z}] ; \forall t_z \in T$ y $\forall j \in N_{bcd}$. Mientras que las variables de decisión de las baterías son $y_B=[P_{Bdk}^{t_z}, P_{Bck}^{t_z}] ; \forall t_z \in T$ y $\forall k \in N_B$.

En las restricciones de desigualdad a variable se debe de tomar en cuenta la predicción de la incertidumbre $w_j^{t_z}$ por esta razón se tienen que redefinir las restricciones de desigualdad a variable incluyendo estas perturbaciones a través de restricciones de probabilidad. Por ejemplo, la probabilidad de que las restricciones de los limites potencia sean violadas [50].

$$prob(S_i P_{t_z}^G \leq s_i) \geq 1 - \alpha, 0 < \alpha_i < 1, \forall t_z \in T \quad (46)$$

Donde $prob()$ es la función de probabilidad, S_i y s_i son parámetros que están definidos con respecto a los límites de generación y α_i el nivel de probabilidad definida por el usuario que los limites sea violados. Note que las restricciones de desigualdad a variable normales pueden ser aproximadas por restricciones de probabilidad con un valor establecido de α_i positivo y muy pequeño.

Para resolver la probabilidad en (46), se usa: (i) regla de adición para variables independientes que siguen la distribución de Gauss, y (ii) cálculo de probabilidad mediante la función de distribución acumulada. Supongamos que X e Y son dos procesos aleatorios independientes, con $X \sim N(\mu_x, \sigma_x)$ y $Y \sim N(\mu_y, \sigma_y)$ entonces:

$$rX + sY \sim N(r\mu_x + s\mu_y, r^2\sigma_x^2 + s\sigma_y^2) \quad (47)$$

$$prob(X < \lambda) \geq \xi \rightarrow \sigma_x \Phi^{-1}(\xi) \leq \lambda - \mu_x \quad (48)$$

Donde $r, s \in \mathbb{R}$ son los coeficientes reales, λ es una variable real, ξ es el nivel de probabilidad y Φ es la función estándar de probabilidad Gaussiana acumulativa. Con esto la ecuación (48) queda de la siguiente forma [50].

$$\|S_i W \odot \sigma_{t_z}\|_2 \Phi^{-1}(1 - \alpha_i) \leq s_i - S_i (D_{ut_z} + V_{vk}) \forall t_z \in T \quad (49)$$

Donde $\sigma_{t_z} = [\sigma_{t_z}^{PV}, \sigma_{t_z}^{Wind}, \sigma_{t_z}^{Load}]$ es el vector de variables de desviación aleatoria en w_{t_z} . Esto introduce una restricción de probabilidad al modelo de la optimización.

3.2. Modelo de MPC para micro-redes

En esta sección se describe la formulación de la estrategia de control para el EMS en una micro-red: la estrategia de control se basa en MPC en el que se plantea como un problema de optimización resuelto por AG (Algoritmo genéticos) [54], [55], [56]. El principal desafío en la gestión de la energía de las micro-redes son las perturbaciones externas debido al uso de fuentes de energía renovables como solar y eólica. El MPC se presenta como una solución confiable, sólida y válida para contrarrestar las incertidumbres que se encuentran en las micro-redes, además agregando un predictor de las perturbaciones externas mediante métodos de predicción como método al MPC el EMS se vuelve robusto y efectivo. Esta metodología se ha utilizado con éxito en sistemas de energía eléctrica [57], [58].

En la Figura 3.1, se propone la estructura del EMS para este trabajo. Como se muestra, los comandos generados por el EMS se envían a los convertidores, luego la información de predicción se envía al controlador MPC, que puede predecir las salidas del sistema relacionadas con la micro-red. Los convertidores utilizados para este trabajo son un convertidor buck-boost para la conexión del sistema fotovoltaico, un convertidor buck-boost bidireccional para la carga y descarga del sistema de almacenamiento y un convertidor buck-boost para la turbina eólica. El bloque de interfaz representa el flujo de información entre los sensores de la microrred y el MPC.

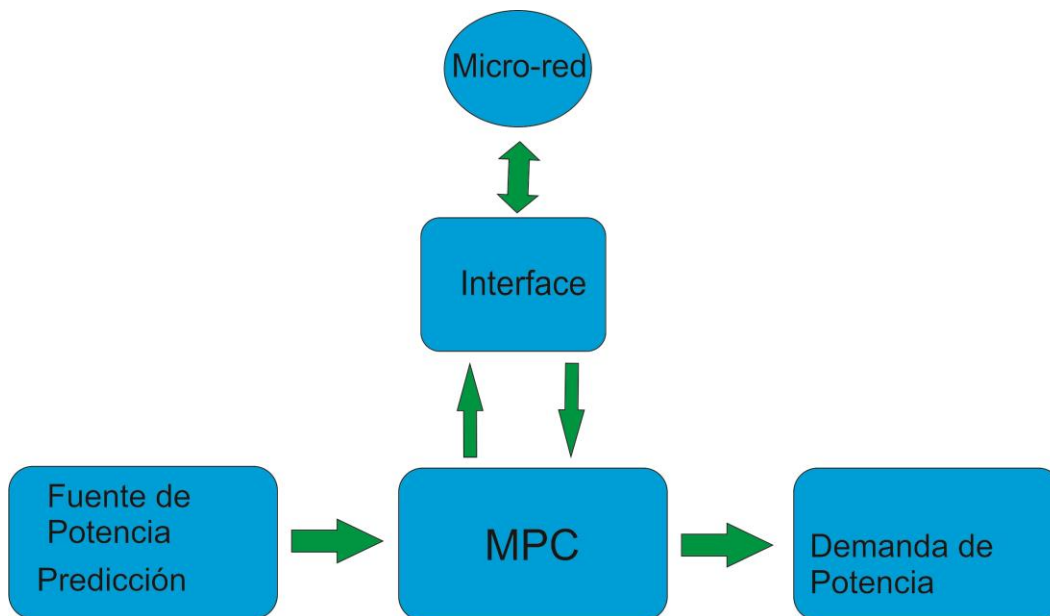


Figura 3.1. La estructura de un EMS

El control predictivo no se refiere a una estrategia de control particular sino a un conjunto de métodos de control que hacen uso explícito de un modelo del proceso para obtener la señal de control minimizando una función objetivo. Las características principales son: Uso explícito de un modelo para predecir la evolución del proceso en los instantes futuros, minimización de una función objetivo, utilización de un horizonte móvil de control finito y deslizante que implica el cálculo de la secuencia de control para todo el horizonte, pero con la aplicación de la primera señal de la secuencia y la repetición de todo el proceso en el siguiente instante de muestreo [59].

La estrategia de los controladores pertenecientes a la familia de MPC se representa en la Figura 3.2.

Las salidas futuras para un horizonte determinado N , llamado horizonte de predicción, se predicen cada instante t utilizando el modelo del proceso. Estas predicciones de la salida $\hat{y}(t+k|t)$ para $k=1$ hasta $k=N$ depende de los valores hasta el instante t y de las señales de control $u(t+k|t)$, $k=0$ hasta $k=N-1$ que han de ser calculada y enviadas al sistema [60].

La secuencia de señales de control futuras se calcula minimizando un criterio para mantener al proceso lo más cerca posible de la trayectoria de referencia $w(t+k|t)$. Este criterio toma normalmente la forma de una función del error cuadrático entre la salida predicha y la trayectoria de referencias futuras. En la mayor parte de los casos se incluye también el esfuerzo de control dentro de la función objetivo. La solución explícita se puede obtener cuando el criterio es cuadrático y el modelo lineal; en caso contrario se ha de utilizar un método numérico para buscar la solución. La señal de control $u(t|t)$ se envía al proceso mientras que el resto de las señales calculada no se consideran, ya que en el instante siguiente de muestreo $y(t+1)$ es conocida y los pasos anteriores se repiten con este nuevo valor. Por lo que $u(t+1|t+1)$ se calcula con información diferente y en principio será también diferente de $u(t+1|t)$ [61].

El MPC como se mencionamos anteriormente incluye una estrategia de horizonte móvil deslizante; es decir, cada vez que se desplaza el horizonte hacia el futuro, una vez calculada la secuencia de control óptima, se aplica la primera señal de control para $k = 1$, $u(t)$ y se descarta el resto para recalculer la secuencia de control en el siguiente instante de tiempo, $k = 2$, con información nueva y actualizada [61].

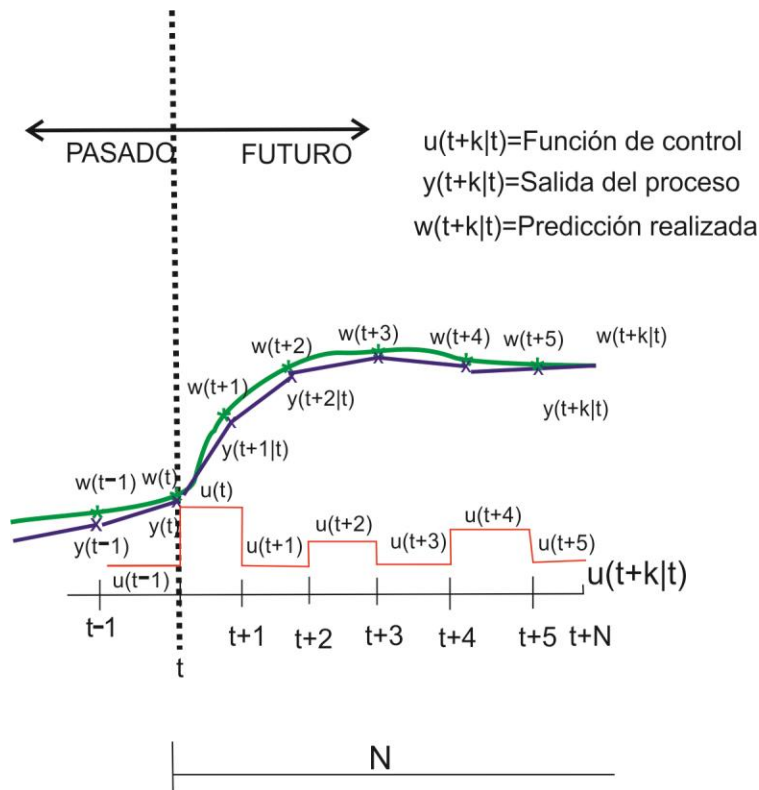


Figura 3.2. MPC

La Figura 3.3 muestra la estructura básica necesaria para implementar el control predictivo. Se usa un modelo para predecir la evolución de la salida o estado del proceso a partir de las señales de entrada y salidas conocidas. Las acciones de control futuras se calculan con el optimizador, que considera la función del coste y las posibles restricciones [62].

El modelo de proceso juega, en consecuencia, un papel decisivo en el controlador. El modelo elegido debe ser capaz de capturar la dinámica del proceso para predecir de forma precisa la evolución del sistema. Al mismo tiempo, debe ser suficientemente simple de implementar y entender. Las distintas metodologías del control predictivo difieren fundamentalmente en el tipo de modelo utilizado [63].

El optimizador es otra parte fundamental de la estructura ya que permite obtener las acciones de control a aplicar. Si la función de coste es cuadrática, el modelo lineal y no existen restricciones, se puede obtener una solución explícita. Si este no es el caso se ha de acudir a un algoritmo numérico de optimización que requiere mayor capacidad de cálculo. El tamaño del problema resultante depende del número de variables, de los horizontes de control y predicción y del número de restricciones, aunque se puede decir que en general problemas de

optimización resultantes en este contexto son problemas más bien modestos [59].

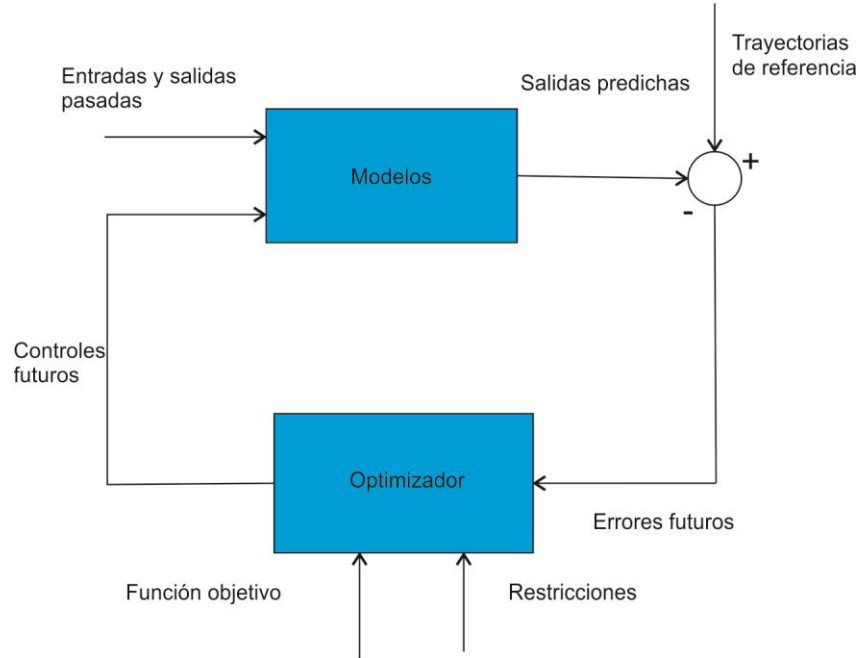


Figura 3.3. Estructura Básica de MPC [59]

El control predictivo se puede considerar una técnica madura para sistemas lineales y no muy rápidos como los encontrados normalmente en la industria de procesos. Sistemas más complejos, tales como sistemas no lineales, híbridos, y o sistemas muy rápidos, eran considerados como fuera del alcance de los controladores predictivos. Durante los últimos años se han producido resultados espectaculares en estos campos. Se ha demostrado que un controlador predictivo con restricciones lineales resulta ser un controlador afín a trozos que puede ser implementado con poca carga de computación. Recientemente han aparecido en la literatura aplicaciones de los controladores predictivos a sistemas no lineales o híbridos [64].

3.3. Algoritmo genético (Método de optimización)

Un algoritmo genético (AG) es un método para solucionar problemas de optimización con o sin restricciones basándose en un proceso de selección natural que imita la evolución biológica. Este algoritmo modifica repetidamente una población de soluciones individuales. En cada paso, el algoritmo genético selecciona individuos de la población actual aleatoriamente y los utiliza como padres para producir los hijos de la siguiente generación. Tras varias generaciones sucesivas, la población "evoluciona" hacia una solución óptima [65]. El algoritmo genético se puede aplicar para solucionar problemas que no se adaptan bien a los algoritmos de optimización estándar, incluidos aquellos problemas en los que la función objetivo es

discontinua, no diferenciable, estocástica o altamente no lineal como es este caso. El algoritmo genético difiere de un algoritmo de optimización clásico basado en derivadas de dos formas principales, tal y como se resume en la tabla siguiente [65].

Tabla 3.1 Diferencias generales entre algoritmos clásicos y genéticos.

Algoritmo Clásico	Algoritmo Genético
Genera un solo punto en cada iteración. La secuencia de puntos se aproxima a la solución óptima.	Genera una población de puntos en cada iteración. El mejor punto de la población se aproxima a la solución óptima.
Selecciona el siguiente punto de la secuencia de una forma determinista.	Selecciona la siguiente población mediante un cálculo que suele basarse, al menos en parte, en el azar.

Los algoritmos genéticos buscan el espacio de solución de una función mediante el uso de la evolución simulada, es decir, la estrategia de supervivencia del más apto. En general, los individuos más aptos de cualquier población tienden a reproducirse y sobrevivir a la siguiente generación, mejorando así las generaciones sucesivas. Sin embargo, los individuos inferiores pueden, por casualidad, sobrevivir y también reproducirse. Se ha demostrado que los algoritmos genéticos resuelven problemas lineales y no lineales mediante la exploración de todas las regiones del espacio de estados y la explotación exponencial de áreas prometedoras a través de operaciones de mutación, cruce y selección aplicadas a los individuos de la población.

El uso de un algoritmo genético requiere la determinación de seis cuestiones fundamentales: la representación cromosómica, la función de selección, los operadores genéticos que componen la función de reproducción, la creación de la población inicial, los criterios de terminación y la función de evaluación.

3.3.1. Representación cromosómica

Para cualquier AG, se necesita una representación cromosómica para describir a cada individuo en la población de interés. El esquema de representación determina cómo se estructura el

problema en el AG y también determina los operadores genéticos que se utilizan. Cada individuo o cromosoma está formado por una secuencia de genes de un determinado alfabeto. Un alfabeto puede constar de dígitos binarios (0 y 1), números flotantes, números enteros, símbolos (es decir, A, B, C, D), matrices, etc. En el diseño original de Holland, el alfabeto estaba limitado a dígitos binarios. Desde entonces, la representación de problemas ha sido objeto de mucha investigación. Se ha demostrado que las representaciones más naturales son más eficientes y producen mejores soluciones [66]. Una representación útil de un individuo o cromosoma para la optimización de funciones implica genes o variables de un alfabeto de números flotantes con valores dentro de los límites superior e inferior de las variables. Michalewicz et al [66] ha realizado una amplia experimentación comparando AG binarios y de valor real y muestra que el AG de valor real es un orden de magnitud más eficiente en términos de tiempo de CPU. También muestra que una representación de valor real acerca el problema a la representación del problema, lo que ofrece una mayor precisión con resultados más consistentes en las repeticiones [66].

3.3.2. Función de selección

La selección de individuos para producir generaciones sucesivas juega un papel extremadamente importante en un algoritmo genético. Se realiza una selección probabilística basada en la aptitud del individuo de modo que los mejores individuos tengan una mayor probabilidad de ser seleccionados. Un individuo de la población puede seleccionarse más de una vez y todos los individuos de la población tienen la posibilidad de ser seleccionados para reproducirse en la siguiente generación. Hay varios esquemas para el proceso de selección: selección de la rueda de la ruleta y sus extensiones, técnicas de escalado, torneo, modelos elitistas y métodos de clasificación [67], [66]. Un enfoque de selección común asigna una probabilidad de selección, P_j , a cada individuo, j con base en su valor de aptitud. Se genera

una serie de N números aleatorios y se compara con la probabilidad acumulada $C_i = \sum_{j=1}^i P_j$ de

la población. El individuo apropiado, i , se selecciona y se copia en la nueva población si $C_{i-1} < U(0,1) \leq C_i$. Existen varios métodos para asignar probabilidades a los individuos: rueda de la ruleta, clasificación lineal y clasificación geométrica. La rueda de la ruleta, desarrollada por Holland et al [68], fue el primer método de selección. La probabilidad, P_i para cada individuo

está definida por $P[i] = F_i / (\sum_{j=1}^{SizeP} F_j)$ donde F_i es igual al fitness del individuo i . El uso de la

selección de la rueda de la ruleta limita el algoritmo genético a la maximización ya que la función de evaluación debe mapear las soluciones a un conjunto completamente ordenado de valores en \Re . Se han propuesto extensiones, como ventanas y escalado, para permitir la minimización y la negatividad a la maximización ya que la función de evaluación debe mapear las soluciones a un conjunto completamente ordenado de valores en \Re . Se han propuesto extensiones, como ventanas y escalado, para permitir la minimización y la negatividad [69].

Los métodos de clasificación solo requieren que la función de evaluación asigne las soluciones a un conjunto parcialmente ordenado, lo que permite la minimización y la negatividad. Los métodos de clasificación asignan P_i en función del rango de la solución i cuando se ordenan todas las soluciones. Clasificación geométrica normalizada [70], de fitness P_i para cada individuo por ecuación 50:

$$P[i] = q^r (1-q)^{P-i} \quad (50)$$

Donde q es la probabilidad de seleccionar al mejor individuo, r el rango del individuo, donde 1 es el mejor, P es el tamaño de población y $q^r = q / (1-q)^P$.

3.3.3. Operadores genéticos

Los operadores genéticos proporcionan el mecanismo de búsqueda básico del AG. Los operadores se utilizan para crear nuevas soluciones basadas en soluciones existentes en la población. Hay dos tipos básicos de operadores: cruce y mutación. El cruce toma dos individuos y produce dos nuevos individuos, mientras que la mutación altera a un individuo para producir una única solución nueva. La aplicación de estos dos tipos básicos de operadores y sus derivados depende de la representación cromosómica utilizada. Sean \bar{X} e \bar{Y} dos vectores fila m -dimensionales que denotan individuos (padres) de la población. Para los binarios \bar{X} e \bar{Y} , los siguientes operadores binarios: mutación binaria y cruce simple.

La mutación uniforme selecciona aleatoriamente una variable, j , y la iguala a un número aleatorio uniforme $U(a_i, b_i)$ como se muestra en ecuación (51) [69].

$$x_i' = \begin{cases} U(a_i, b_i), & \text{si } i=j \\ x_i, & \text{en otro caso} \end{cases} \quad (51)$$

La mutación de límite selecciona aleatoriamente una variable, j , y la iguala a su límite inferior o superior, que se representa en ecuación (52):

$$x'_i = \begin{cases} a_i, & \text{si } i = j, r < 0.5 \\ b_i, & \text{si } i = j, r \geq 0.5: \\ x_i & \text{otro caso} \end{cases} \quad (52)$$

La mutación no uniforme selecciona aleatoriamente una variable, j , y la iguala a un número aleatorio no uniforme.

El operador de mutación multi-nouniforme aplica el operador no uniforme a todas las variables en el \bar{X} padre.

3.3.4. Inicialización, terminación y evaluación de la función

Al AG se le debe proporcionar una población inicial. El método más común es generar soluciones aleatoriamente para toda la población. Sin embargo, dado que los AG pueden mejorar iterativamente las soluciones existentes (es decir, soluciones de otras heurísticas y/o prácticas actuales), la población inicial puede iniciarse con soluciones potencialmente buenas, y el resto de la población son soluciones generadas aleatoriamente.

El AG se mueve de generación en generación seleccionando y reproduciendo padres hasta que se cumple un criterio de terminación. El criterio de parada utilizado con más frecuencia es un número máximo especificado de generaciones. Otra estrategia de terminación implica criterios de convergencia de población. En general, los AG obligarán a gran parte de la población a converger hacia una única solución. Cuando la suma de las desviaciones entre individuos se vuelve más pequeña que algún umbral especificado, el algoritmo puede terminar. El algoritmo también se puede terminar debido a la falta de mejora en la mejor solución durante un número específico de generaciones. Alternativamente, se puede establecer un valor objetivo para la medida de evaluación basado en algún umbral "aceptable" arbitrariamente. Se pueden usar varias estrategias en conjunto [69].

Las funciones de evaluación de muchas formas se pueden utilizar en un GA, sujetas al requisito mínimo de que la función pueda mapear la población en un conjunto parcialmente ordenado. Como se indicó, la función de evaluación es independiente del GA (es decir, reglas de decisión estocásticas).

3.4. Implementación computacional para el análisis de la optimización

La descripción de la implementación de los algoritmos se resume por medio del algoritmo representativo mostrado en la Figura 3.4. Los componentes de este algoritmo se describen enseguida.

Procesamiento de Datos: la implementación computacional del análisis del modelo de optimización para el control terciario (EMS) inicia leyendo los datos de radiación solar para después calcular los parámetros de un modelo geométrico, el siguiente paso es ejecutar el algoritmo del modelo estocástico de la radiación solar y velocidad de viento tomando en cuenta los datos históricos de varios años utilizando series de tiempo. Se debe de leer los datos técnicos de la micro-red y los parámetros para configurar la ejecución del método de optimización seleccionado (método de algoritmo genético). Dichos datos y parámetros son proporcionados por el usuario por medio de variables en un archivo .m independiente.

Modelo de optimización inicial: para proceder a la solución del modelo (39)-(44), es primeramente necesario obtener un valor aproximado de la potencia intercambiada entre el sistema de almacenamiento y los generadores renovables de la micro-red a lo largo del intervalo T . Para este fin, se resuelve un modelo de optimización similar a (39) -(44) que no incluye las restricciones de igualdad (42); lo cual se ha denominado modelo de optimización dinámico inicial. En este modelo el balance de potencia de la micro-red se plantea por medio de una restricción de balance general que modela la igualdad entre la potencia generada y consumida de la micro-red; asumiendo que las fuentes de generación (baterías, aerogeneradores, etc.) y las cargas se conectan en un mismo nodo, es decir, sin considerar las ecuaciones de balance nodal. La función objetivo de este modelo es exactamente la misma utilizada en el modelo de optimización de la micro-red. (39)-(44). Por lo tanto, en esta etapa, el algoritmo invoca la evaluación tanto de la función objetivo (42) y de la restricción de balance general, para evaluar y resolver el modelo de optimización inicial. La solución de este modelo se considera el valor inicial de las variables de decisión que representan la potencia intercambiada en la micro-red.

Condiciones iniciales: En esta etapa del algoritmo se asignan las condiciones iniciales de las variables de decisión y en particular las condiciones iniciales de la potencia intercambiada en la micro-red entre los generadores, las cargas y sistemas de almacenamiento, se obtiene el modelo de optimización dinámico inicial. Mientras que las variables de voltaje se les da un valor

inicial y las corrientes se les da un valor inicial de aproximado, estos valores sirven como población inicial para el algoritmo genético.

Análisis modelo de optimización de la micro-red: En esta etapa, por medio del método de optimización seleccionado (algoritmos genéticos) se resuelve el modelo (39)-(44). Cuya solución proporciona el valor óptimo y_* de las variables de decisión. De esta manera, el manejo óptimo de la energía está determinado. Note que el modelo (39)-(44) ha sido implementado en dos funciones (función objetivo y restricciones redefinidas por las perturbaciones de incertidumbre), las cuales son invocadas por el método de optimización seleccionado.

Flujos de red: En esta etapa, el algoritmo realiza los cálculos de potencia activa a través de cada uno de los elementos que componen la micro-red.

Impresión de resultados: El algoritmo termina proporcionando la impresión de resultados obtenidos del análisis modelo de optimización de la micro-red para el control terciario (EMS).

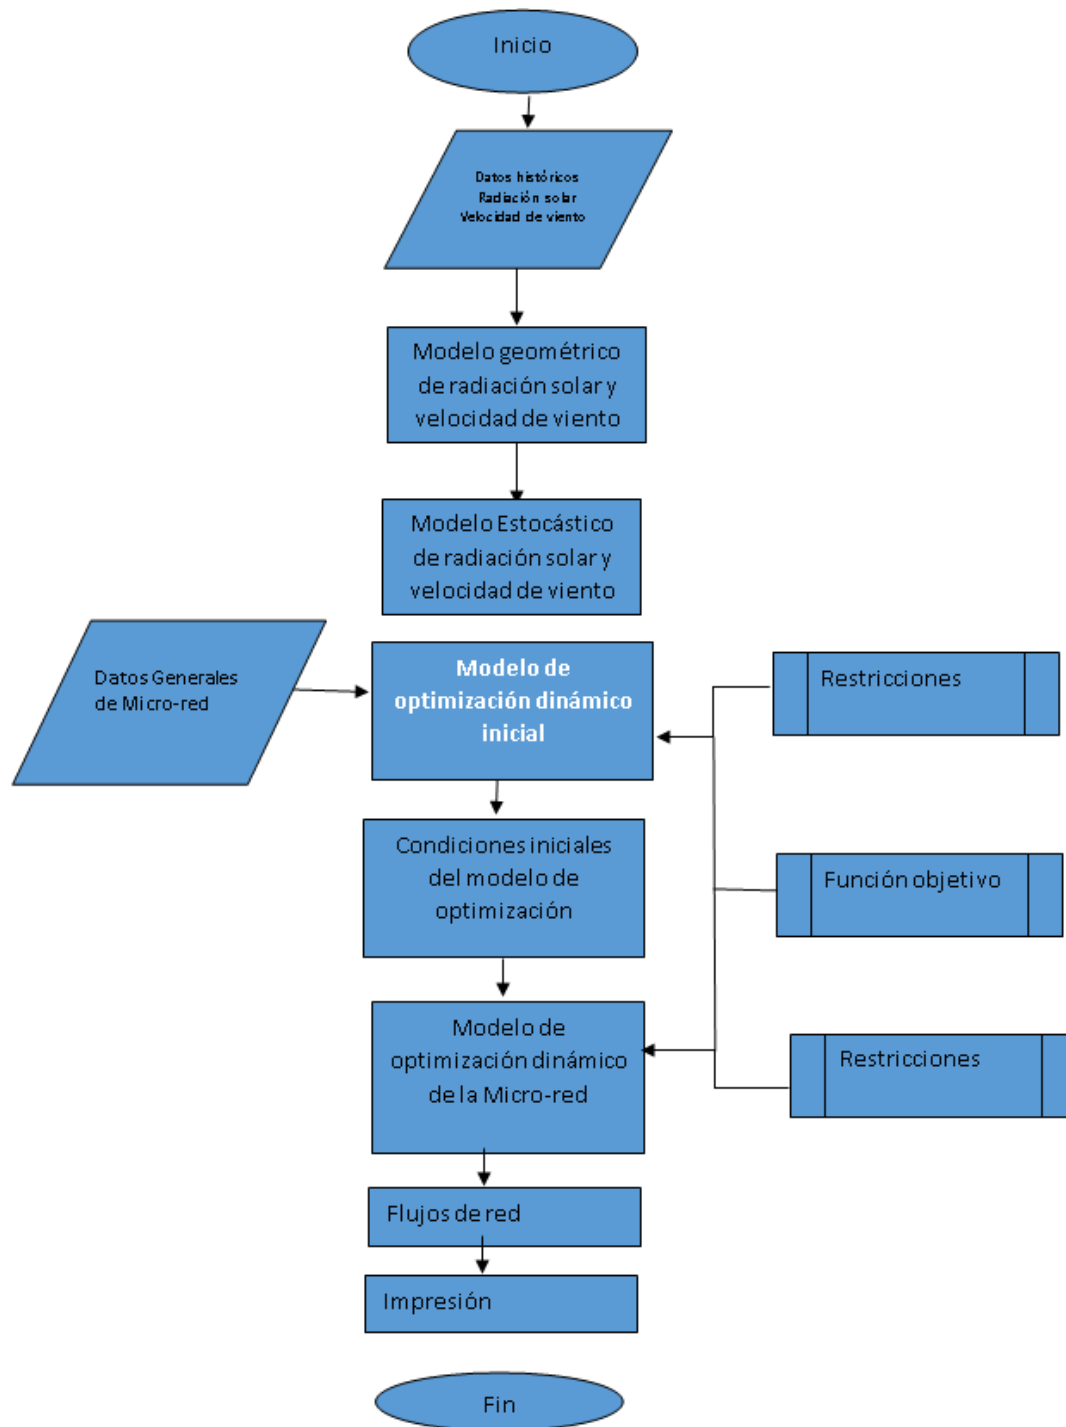


Figura 3.4. Algoritmo computacional de optimización para micro-redes (fuente propia)

3.5. Tomador de decisiones para optimización multiobjetivo

La estructura utilizada para el tomador de decisiones en este trabajo se basa en el enfoque del ciclo interno que crea un algoritmo para calcular un conjunto de soluciones para una pequeña

parte del problema multiobjetivo (Vea tabla 3.2). Estos problemas menores se denominan problemas locales porque solo involucran algunos factores del problema. En el caso de este trabajo, solo aplica la cantidad donde se requiera para optimizar el costo de la energía en el momento en que los niveles de contaminación sean los más bajos, el caso donde sea necesario minimizar los niveles de CO₂ emitidos al medio ambiente porque los niveles de contaminación en la ciudad son los más altos. Si los niveles de contaminación son intermedios, se puede elegir una solución de compromiso que se adapte bien a la situación. La idea clave detrás del enfoque del ciclo interno, si estos problemas locales están bien elegidos y condicionados, entonces sus soluciones, es decir, las soluciones locales, pueden conducir directamente a una solución completa [71].

En cada iteración, se identifica un vector no P-dominado de la entrada V1. A partir de un vector de valor aleatorio V, se hacen comparaciones por pares con los otros vectores de valor en V1. Si V está dominado por Pareto por un vector V, ese vector reemplaza a V como el vector de valor actual. Este proceso asegura que al final de las comparaciones, el V final no está por P-dominado.

Tabla 3.2 Estructura de tomador de decisiones.

```

Start
V*=0
While (V1≠/0) do
V=V1(1,1)
  For V*=V1
    If(V*>V1) then
      V=V*
    End if
  End For
Remove V, and all vectors (weakly) P-dominado by V, from V
End while
Return V*

```

Con respecto al resto de los vectores de valor en V1, una vez identificado este V, se traslada al conjunto de resultados V * que se convertirá en un conjunto completo de cobertura de Pareto. Además, todos los vectores dominados por V se eliminan de V1. Esta eliminación asegura que ningún vector en V1 esté dominado por uno en V *. En otras palabras, no se retienen vectores de valor en exceso. Por lo tanto, sabemos que ningún vector dominado por un vector en V * se suma a V * [71].

CAPÍTULO 4.

RESULTADOS Y DISCUSIÓN

En esta sección se presentan y discuten los resultados preliminares relacionados al manejo óptimo de la energía en micro-redes, obtenidos por medio de las herramientas computacionales para el análisis de modelo de optimización de micro-redes. Para este fin, primeramente, se describe una micro-red de prueba MCR1 considerada con los elementos de generación, almacenamiento y cargas dimensionados para la micro-red del vehículo autónomo marítimo. También se muestran los resultados para una micro-red de prueba MCR2 que se dimensionó para un vehículo autónomo terrestre de la Universidad de Almería, obtenidos por medio de un MPC de modo deslizante implementado en Matlab y con horizonte de predicción variable, se realiza la descripción de los elementos de la micro-red. Una variante de la micro-red anterior se analiza cómo caso de prueba MCR3 esta micro-red se conecta a la red principal a través de un punto de acoplamiento común y se convierte en una micro-red no autónoma, los resultados se obtienen a través de un MPC de modo deslizante con horizonte de predicción variable en este caso usando algoritmo genético como método de optimización. Una cuarta micro-red de prueba MCR4 se implementó con un elemento electrógeno de respaldo, carga en AC de laboratorio 6 de CIESOL en la Universidad de Almería y con funciones de costo de potencia variable para la red principal y el elemento electrógeno, los resultados se obtuvieron con un MPC de control deslizante, horizonte de predicción variable y función de costo variable. Para el análisis de optimización multiobjetivo se planteó una variación de las potencias de los elementos de MCR4 los resultados se obtuvieron con un MPC y fue resuelto mediante algoritmo de optimización multiobjetivo de AG. El análisis del modelo de optimización y MPC de modelo deslizante fueron ejecutados en una computadora personal PC DELL, 8 GB de memoria RAM y procesador i5-4210U CPU@ 2.40 GHz.

4.1. Resultados de algoritmo de optimización

La micro-red MCR1 es de tipo autónoma como se muestra en la Figura 4.1, está compuesta de elementos básicos: módulo fotovoltaico, batería, aerogenerador tidal y carga. Esta red es entonces considerada un caso de estudio para mostrar los resultados del manejo óptimo de la energía obtenidos a partir de las herramientas desarrolladas. En este trabajo se consideran datos reales de irradiación solar, velocidad de viento de la ciudad de Cancún y la curva de demanda eléctrica de los motores que moverán el vehículo marítimo autónomo. Se aclara que

los elementos de la red que conectan los pares de nodos 1-2, 3-4 y 5-6 son convertidores de potencia necesarios para la regulación de voltaje y corriente de las fuentes de generación hacia el bus CD que alimenta los motores del vehículo autónomo marítimo. Los demás elementos que interconectan dos nodos adyacentes representan segmentos de líneas de distribución que forman parte de la micro-red. En este caso, los elementos que tienen capacidad de proporcionar soporte de potencia activa son el aerogenerador tidal, el módulo fotovoltaico y la batería. Los parámetros considerados en los modelos de los componentes de esta micro-red de prueba, así como los coeficientes de costo asociados a la energía de los elementos generadores se presentan en el apéndice A.




Figura 4.1. Micro-red de estudio MCR1 (fuente propia)

Para el caso de estudio se ha considerado la micro-red de prueba. Para fines de análisis se considera la curva de demanda de potencia activa mostrada en la Figura 4.2.a Las curvas de irradiación solar y velocidad de viento calculadas se muestran en las Figura 4.2.b y Figura 4.2.c, respectivamente. Estas dos curvas son típicas de la ciudad de Cancún Quintana Roo, y fueron proporcionadas por el Servicio meteorológico nacional de México. En relación con el sistema en datos reales, los límites de las magnitudes de voltaje para todos los nodos en CD de la micro-red son $0.95 \leq V_{t_z} \leq 1.05$ (en %). Los límites del estado de carga de las baterías son

$0.2 \leq SOC_t \leq 0.95$ (en %). Además, se ha especificado que la batería tiene un estado inicial de $SOC_0 = 0.20$ (en %). Para este caso de estudio, el análisis del modelo de optimización de la micro-red fue realizado utilizando el método de algoritmos genéticos proporcionado por el toolbox de Matlab®. Los resultados obtenidos se muestran y discuten a continuación.

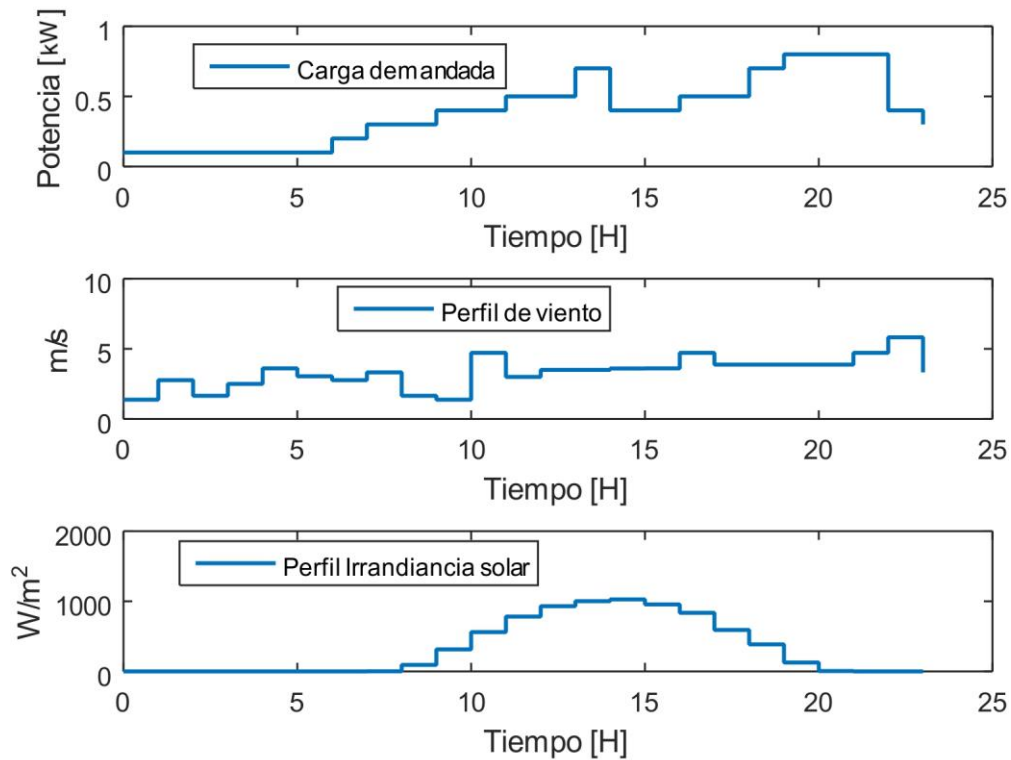


Figura 4.2. Curvas pronosticadas; a) demanda de potencia activa, b) irradiación solar y c) velocidad de viento. (fuente propia)

La Figura 4.3 muestra la potencia activa proporcionada por la batería, aerogenerador y módulo fotovoltaico. Se observa que un mayor porcentaje de la curva de demanda (ver Figura 4.2.a) se abastece en mayor parte de la potencia producida por el aerogenerador, es claro que la producción del aerogenerador tiene una tendencia similar a la curva de velocidad de viento mostrada en la Figura 4.2.c), debido a que la función de potencia del aerogenerador depende directamente de la velocidad de viento. Se observa además que el panel fotovoltaico tiene su mayor aportación de energía entre las 10:00 y 19:00 hrs, lo cual coincide con el periodo de mayor irradiación (ver Figura 4.2.b). La batería experimenta periodos de carga ($P_{Bn}^{fz} < 0$) y descarga ($P_{Bn}^{fz} > 0$). En particular, se observa que en los periodos donde existe mayor

generación eólica (p.e. en las hrs. 4, 10, 17 y 22) la batería se encuentra en proceso de carga ($P_{Bn}^t < 0$). Esta energía es útil para alimentar los motores del vehículo marítimo autónomo cuando las fuentes renovables no generan suficiente (p.e. en la hora 9, 13 y 20 hrs). Lo anterior coincide con el SOC resultante e ilustrado en la Figura 4.4, además se ve que en la última hora la batería se aprovecha a cargar debido a la mayor producción del aerogenerador.

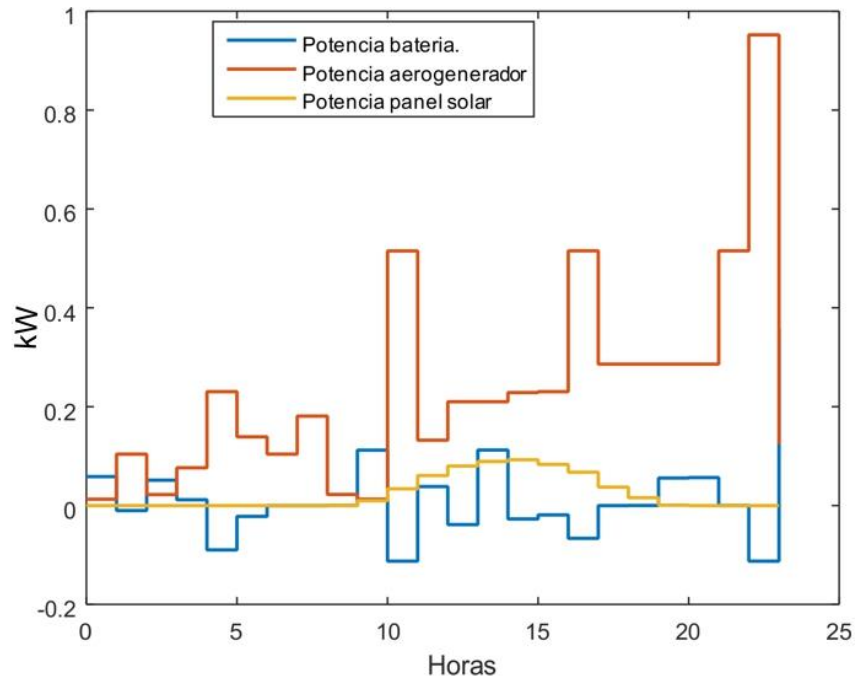


Figura 4.3. Curvas de generación de la micro-red (fuente propia)




Figura 4.4. Estado de carga de la batería (SOC) (fuente propia)

4.2. Resultados de métodos de series de tiempo para predicción de radiación solar y velocidad de viento

Los métodos de predicción presentados en la sección 2.8. se implementaron utilizando Matlab. Se inicia desde la etapa $t_z = 0$, a las 6:00 AM, la predicción se realiza solo un paso adelante en el tiempo $t_z = 1$ (6:15 AM) con un período de 15 minutos (el período se puede cambiar a 10, 15, 30 y 60 minutos), los datos de las Figura 4.5 y Figura 4.6 son datos reales de irradiancia y velocidad de viento para un día de verano despejado de la ciudad de Almería España recogidos de la estación meteorológica ubicada en el edificio de CIESOL (Centro de Investigación en Energía Solar). Se agrega el ruido R a los datos, obtendremos la medición del sensor y se la proporcionamos al filtro de Kalman para refinar la estimación del estado en el tiempo $t_z = 1$. El proceso ahora ya está en $t_z = 1$, la predicción se está haciendo nuevamente para $t_z = 2$ y paso a paso hasta que llegemos al final de los datos de referencia a las 7:30 PM $t_z = 54$. La predicción realizada con método de doble exponencial suavizado toma el valor actual de la serie de observación y se utiliza para calcular su valor de reemplazo suavizado. En este caso, utilizamos la última observación para calcular el valor de reemplazo suavizado actual.

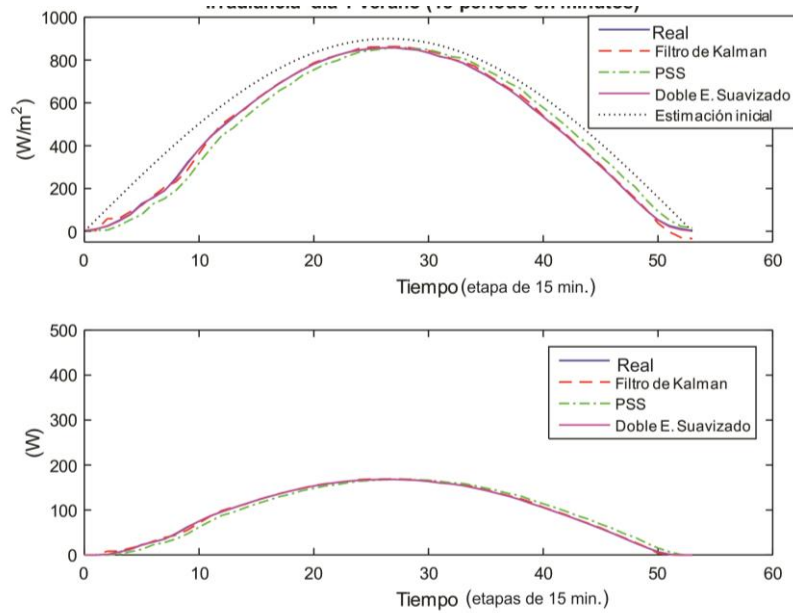


Figura 4.5. Predicción de Irradiancia y Potencia PV (fuente CIESOL)

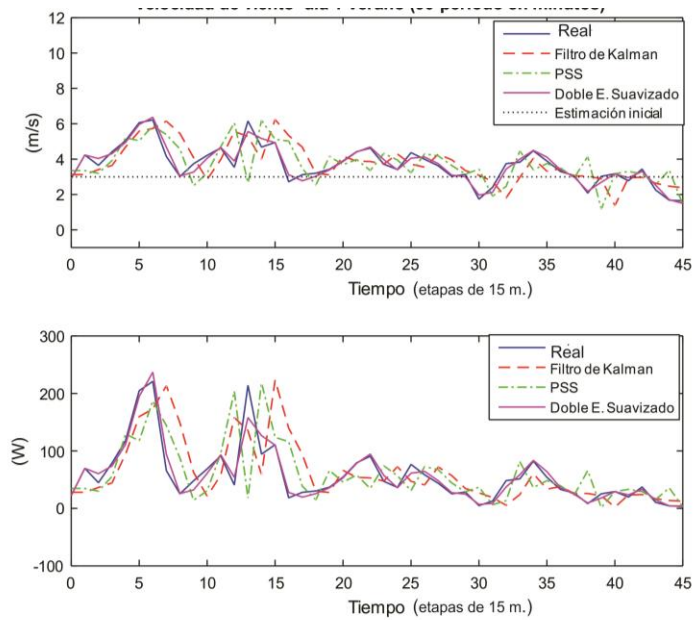


Figura 4.6. Predicción de Velocidad de viento y Potencia Aerogenerador (fuente CIESOL)

Los resultados de estas predicciones se compararán con los resultados del método de pronóstico persistente PSS. Si estos métodos de predicción pueden superar a PSS, se considera satisfactorio. En la Figura 4.5 se muestra la predicción de radiación solar en la cual se observa la línea de color azul es la radiación real, la línea de color verde es la predicción del método de PSS, la línea color rojo es la predicción de filtro de Kalman y la línea de color magenta es la predicción del método de doble exponencial suavizado. la comparación de la

Figura 4.5 muestra que el método de doble exponencial suavizado es el más cercano en todo momento a la radiación real, también el filtro de Kalman tiene muy buena predicción con respecto a la radiación real pero el mejor es el método doble exponencial suavizado. Figura 4.6 se realiza la predicción para la velocidad de viento del mismo día, es evidente que también el método doble exponencial suavizado realiza la mejor predicción.

Para el método de filtro de Kalman, se realiza una estimación inicial mediante un modelo matemático conocido y se usa como tendencia para predecir el resultado utilizando el modelo de espacio de estado antes de que el filtro de Kalman refine el resultado. Si el modelo matemático es cercano a la salida real, entonces la gota gaussiana de la salida estimada después del filtro de Kalman será menor, lo que resulta en una mejor estimación para la próxima predicción. El problema del filtro de Kalman es que depende mucho del modelo de entrada, por esta razón el método de doble exponencial suavizada presenta mejores características para las tendencias como se ve en las predicciones de las Figura 4.5 y Figura 4.6.

La raíz del error cuadrático medio (*RMSE del inglés root-mean-square error*) para la predicción de radiación solar de la Figura 4.5 se muestra en la Figura 4.7 donde se corrobora que el método de predicción con menor error es el doble exponencial suavizado. Similares resultados se obtienen para la velocidad de viento donde el método doble exponencial suavizado es el que obtiene menor error como lo vemos en la Figura 4.8.

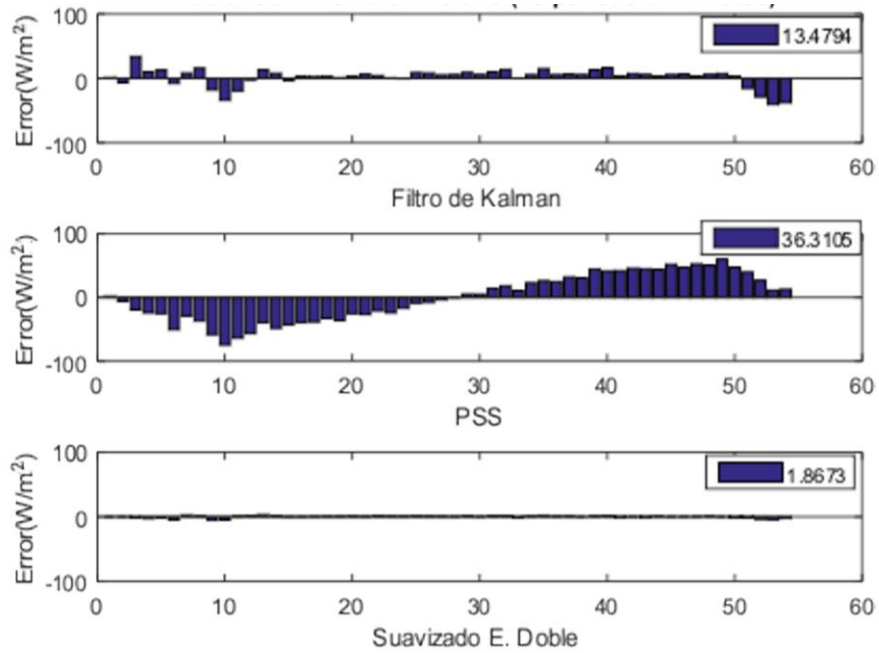


Figura 4.7. RMSE de la irradiación solar (fuente propia)

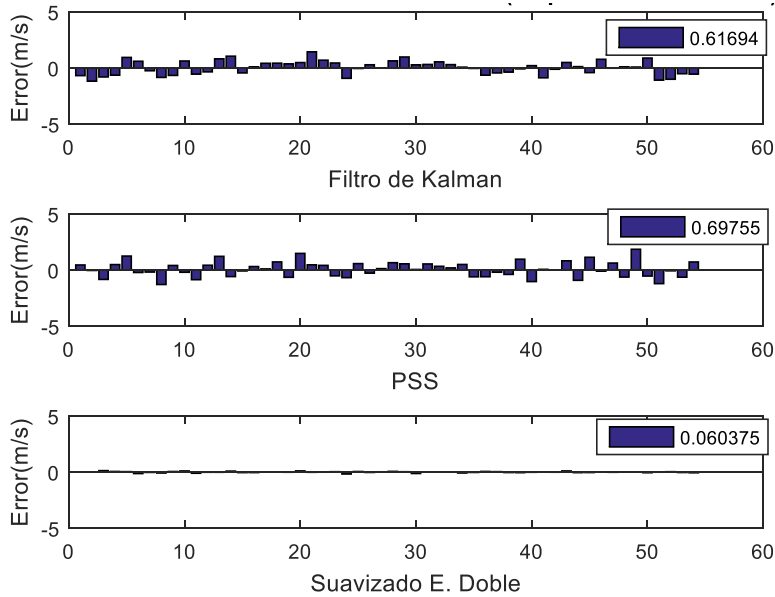


Figura 4.8. RMSE de la velocidad de viento (fuente propia)

El mismo ejercicio se realizó para un día de invierno nublado obteniendo resultados similares con respecto a la calidad de la predicción, se observa en las Figura 4.9 y Figura 4.10 que la predicción más cercana a la real es siempre la del método de doble exponencial suavizada.

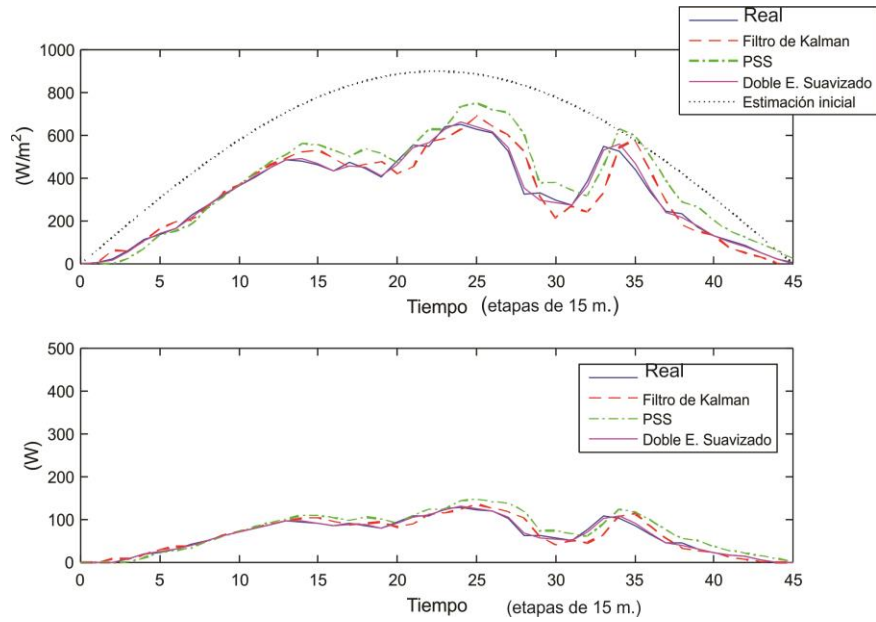


Figura 4.9. Predicción de Irradiancia y Potencia PV de un día de invierno nublado (fuente CIESOL)

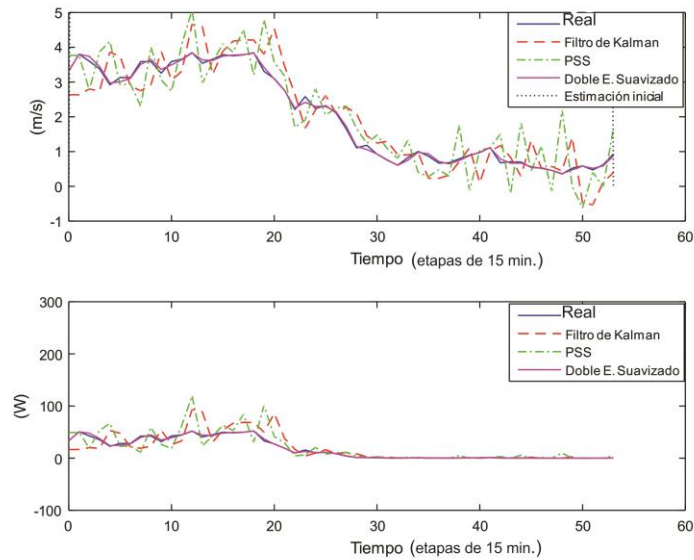


Figura 4.10. Predicción de velocidad de viento y potencia de aerogenerador para un día de invierno nublado (fuente CIESOL)

4.3. Resultados de Modelo de Control Predictivo (MPC)

En esta sección, presentamos tres resultados de simulación que demuestran el rendimiento del esquema de MPC presentado en este documento. En la primera parte de esta sección se presenta la operación de una micro-red a escala de laboratorio de modo autónomo para un

vehículo terrestre con un sistema de almacenamiento de plomo ácido, seguida de una versión no autónoma de la micro-red conectada a la red principal con una función de costo constante, se desarrolló una tercera versión agregando un elemento electrógeno de respaldo (Generador diésel) y función costo variable para la red principal y función de costo variable para el elemento electrógeno .

4.3.1. Resultados de Modelo de Control Predictivo (MPC) para micro-red autónoma

La micro-red de prueba MCR2 para esta simulación es la propuesta en la Figura 4.12 donde se muestra, la carga del automóvil, panel fotovoltaico, aerogenerador tidal, sistema de almacenamiento plomo ácido conectados a través de sus respectivos convertidores. En la sección 4.1. se mostró los resultados de una micro-red autónoma con un EMS planteado como un algoritmo de optimización para CD como flujo óptimo de potencia CD. En este caso se planteó para esta micro-red un modelo de control predictivo deslizante descrito en la sección 1.1.3. con un horizonte de predicción N (cabe mencionar que el horizonte de predicción en este trabajo se puede variar desde $t_z = 2$ hasta $t_z = T$ de etapas) para estas simulaciones $N=10$ que equivale a 2:30 horas t_z de 15 minutos. Para $t_z = 1$ se realiza la optimización de las primeras 10 etapas, se guarda la primera etapa optimizada y se desechan las demás. Se optimizan las siguientes 10 etapas de $t_z = 2$ a $t_z = 11$ se guardará la $t_z = 2$ optimizada y se desechan las demás t_z , en las siguientes etapas se repite el procedimiento hasta llegar a la etapa final T . Para esta simulación se utilizaron los datos radiación solar y velocidad de viento de la Ciudad de Almería España. El perfil de carga es caracterizado de un vehículo terrestre autónomo de la Universidad de Almería. Como se muestra en la Figura 4.11 c).




Figura 4.11. Curvas pronosticadas para MCR2; a) irradiación solar, b) velocidad de viento y c) demanda de potencia activa, (fuente CIESOL)




Figura 4.12. Micro-red de prueba MCR2

En la Figura 4.13 se muestran los perfiles de potencia generada por el sistema fotovoltaico, aerogenerador y sistema de almacenamiento para la micro-red de prueba 2 (MCR2) con un MPC de modo deslizante. La carga del motor del vehículo terrestre es de 3.5 kW, la capacidad del sistema de almacenamiento es de 2 kW, cargada a un 85%, $0.2 \leq SOC_B(t_z) \leq 0.95$, la capacidad máxima del sistema fotovoltaico es de 2 kW y la capacidad del aerogenerador es de 1 kW. Como se mencionó anteriormente el horizonte de predicción es $N=10$, en la Figura 4.13 observamos que el sistema de almacenamiento en las primeras 10 etapas entrega potencia para compensar la carga del motor del vehículo ya que el aerogenerador y sistema fotovoltaico no generan lo suficiente, en las etapas 18 a 35 el sistema fotovoltaico genera una potencia mayor que la necesaria para el motor y la batería aprovecha a cargarse, después de cargarse en las etapas 36 a 45 la batería se descarga para compensar la energía necesaria para la potencia demandada, el comportamiento concuerda con el SOC de la batería como se muestra en la Figura 4.14 a) y Figura 4.15. Además, en la Figura 4.14 b) se muestra el déficit de energía en la micro-red de prueba 2 y en Figura 4.14 c) la energía sobrante o energía amortiguada, en este caso solo hay un déficit de energía para las etapas 10 a 20 y 35 a 54.

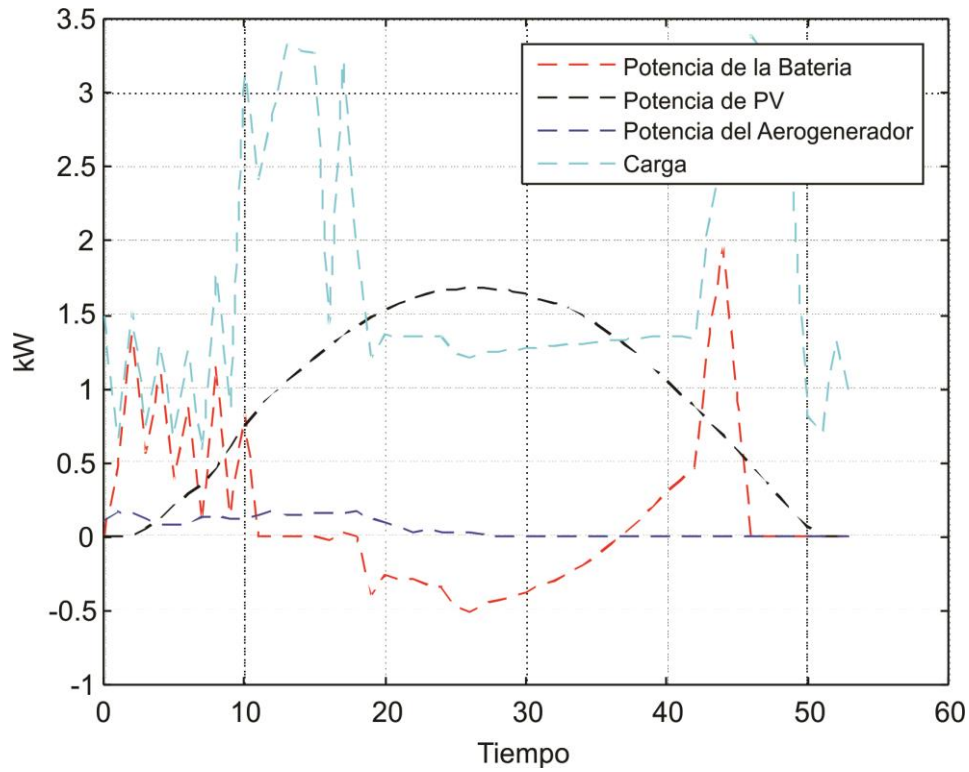


Figura 4.13. Curvas de generación de la micro-red MCR2 (fuente propia)

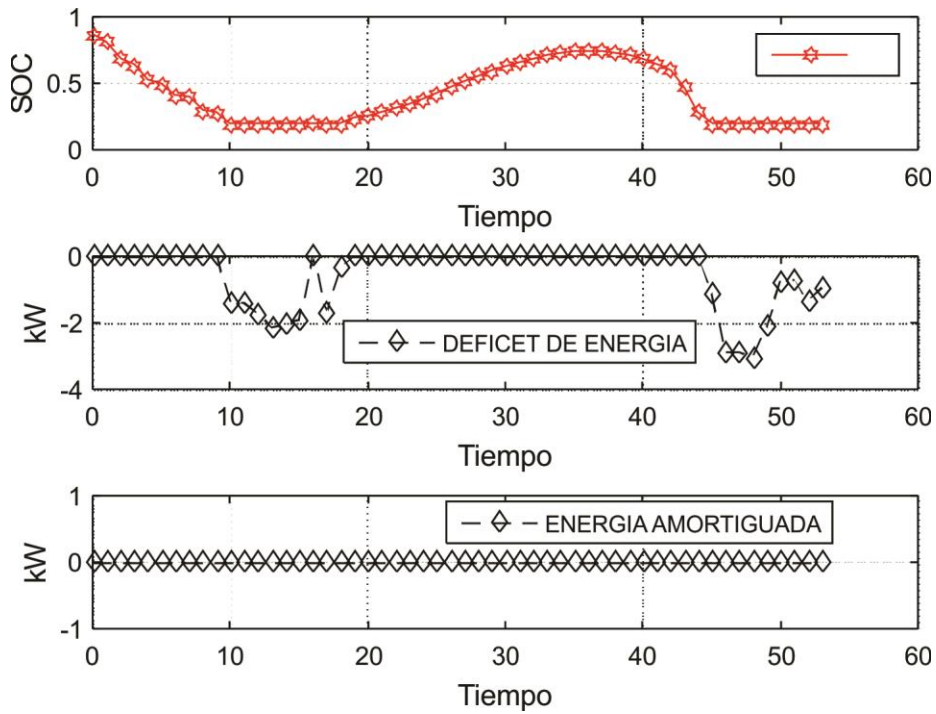


Figura 4.14. Curvas de potencia MCR2; a) SOC Batería, b) Déficit de energía en MCR2 y c) Energía Amortiguada en MCR2. (fuente propia)

En la Figura 4.15 se muestra el comportamiento del SOC para MCR2 el cual concuerda con la curva de carga y descarga de la batería mostrada en la Figura 4.13 por lo cual podemos ver que MPC de modo deslizante aplicado en este trabajo funciona correctamente.




Figura 4.15. SOC Batería MCR2 (fuente propia)

4.3.2. Resultados de Modelo de Control Predictivo (MPC) para una micro-red no autónoma con función de costo constante.

La micro-red de prueba 3 (MCR3) se muestra en la Figura 4.16 y está compuesta por; batería, módulo fotovoltaico, aerogenerador y carga. La micro-red se conecta a la red principal a través del único punto de acoplamiento común (PAC) convirtiéndola en una micro-red no autónoma. Se aclara que los elementos de la red que conectan los pares de nodos 1-2, 3-4 y 5-6 son convertidores CD-CD y en 7-8 es un inversor cargador CA-CD. Los demás elementos que interconectan dos nodos adyacentes representan segmentos de líneas de distribución que forman parte del alimentador principal de la micro-red. En este caso, los elementos que tienen capacidad de proporcionar soporte de potencia activa son la red principal (PAC), aerogenerador, módulo fotovoltaico y la batería. Los parámetros considerados en los modelos de los componentes de esta micro-red de prueba, así como los coeficientes de costo asociados a la energía importada a través del PAC se presentan en el Apéndice A. En la Figura 4.17 a) se muestra los perfiles de radiación solar, Figura 4.17 b) velocidad de viento para un día invierno nublado de la ciudad de Almería España y en Figura 4.17 c) el perfil de demanda de motor de vehículo autónomo.




Figura 4.16. Micro-red de estudio MCR3 (fuente propia)




Figura 4.17. Curvas pronosticadas para MCR3; a) irradiación solar, b) velocidad de viento y c) demanda de potencia activa, (fuente CIESOL)

El horizonte de predicción para la simulación de la Figura 4.18 se fijó en $N=10$ (2:30 horas) inmediatamente se realizó una segunda simulación con el horizonte de predicción $N=4$ (1 hora) que observamos en la Figura 4.19, nos sirve para comparar el MPC de modelo deslizante con diferente horizonte de predicción. Como podemos ver en las Figura 4.18 y Figura 4.19 los círculos rojos marcan que hay pequeñas diferencias en la optimización debido al cambio de horizonte de predicción, se muestran esas diferencias en las etapas 22 y 35 de la Figura 4.18 y Figura 4.19, sin embargo, aunque hay pequeñas diferencias el control predictivo funciona correctamente ya que en los dos casos se satisface la demanda de potencia de la carga. Además, vemos que en los momentos donde el aerogenerador y sistema fotovoltaico produce un excedente de potencia la batería aprovecha a cargarse como lo vemos en la Figura 4.18 en las etapas 5 a 7 y 20 a 27, en momentos donde el sistema fotovoltaico y aerogenerador no son capaces de suplir la potencia entra a funcionar la batería y en último caso la red como lo vemos en las etapas 9 a 21 y 28 a 45. El comportamiento en la segunda simulación es similar y se puede observar en la Figura 4.19.




Figura 4.18. Curvas de generación de la micro-red MCR3 con $N=10$ (fuente propia)




Figura 4.19. Curvas de generación de la micro-red MCR3 con N=4 (fuente propia)

En la Figura 4.20 observamos el comportamiento de SOC de la batería que concuerda con el comportamiento de la curva de carga y descarga de potencia activa de la batería.




Figura 4.20. SOC Batería MCR3 (fuente propia)

4.3.3. Resultados de Modelo de Control Predictivo (MPC) para función de costo variable en el tiempo

La micro-red de prueba 4 (MCR4) se muestra en la Figura 4.21, se agregó como elemento de respaldo un electrógeno (generador diésel), con una función de costo diferente a la función de costo de la red principal. Los parámetros considerados en los modelos de los componentes de esta micro-red de prueba, así como los coeficientes de costo asociados a la energía importada a través del PAC y la del generador diésel se presentan en el Apéndice A. En la Figura 4.22 a) se muestra los perfiles de radiación solar, Figura 4.22 b) velocidad de viento para un día de verano despejado de la ciudad de Almería España y en Figura 4.22 c) el perfil de demanda para el laboratorio 6 del edificio CIESOL.




Figura 4.21. Micro-red de estudio MCR4 (fuente propia)

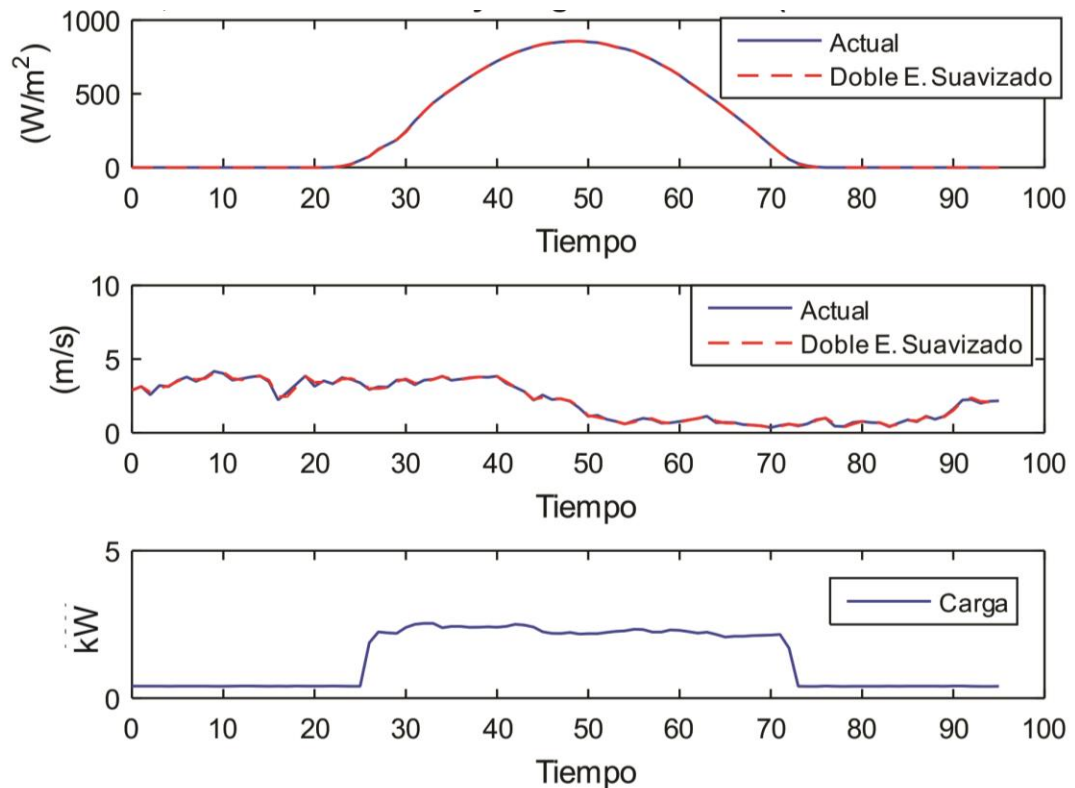


Figura 4.22. Curvas pronosticadas para MCR4; a) irradiación solar, b) velocidad de viento y c) demanda de potencia activa, (fuente CIESOL)

En la Figura 4.23 se muestra la generación de potencia en MCR4 y en la Figura 4.24 el comportamiento de las funciones de costo, la potencia de la red es la línea de color magenta, la línea de color celeste representa la generación de elemento electrógeno (generador diésel), la línea de color rojo es la potencia suministrada y consumida por la batería, la línea de color azul la potencia suministrada por el aerogenerador, la línea de color negro representa la potencia del sistema fotovoltaico y la línea de color amarillo representa la carga del laboratorio. Se observa en la Figura 4.24 el comportamiento del costo de la potencia producida por el generador diésel de color celeste y el costo de la potencia proporcionado por la red principal en color magenta, si vemos las Figura 4.23 y Figura 4.24 en conjunto observamos que el comportamiento de entrega de potencia del generador diésel y la red principal varía según el costo de cada una en las diferentes etapas, observamos que en las etapas 0 a 25 la potencia del aerogenerador es capaz de compensar la demanda de potencia de la carga y además genera un excedente de potencia para cargar la batería. En las etapas 26 a 30 ni la potencia del aerogenerador y el sistema fotovoltaico son capaces de suplir la demanda de la carga por lo cual entra a compensar potencia la red principal que como podemos ver en la Figura 4.24 es más barata que la potencia del generador diésel. En las etapas 31 a 40 la potencia del generador diésel es

más barata por lo cual en este caso el encargado de compensar la potencia es este mismo. De las etapas 41 a 60 la potencia de la red es más barata por lo cual el MPC utiliza esta para compensar la demanda de la carga y por último de las etapas 61 a 75 la potencia del generador diésel es la más económica por lo cual es la que se utiliza para compensar la demanda de la carga.




Figura 4.23. Curvas de generación de la micro-red MCR4 con N=10 (fuente propia)




Figura 4.24. Comportamiento de funciones de costo MCR4 (fuente propia)

En la Figura 4.25 se muestra el SOC de la batería de MCR4 se observa que este concuerda con el comportamiento de los lapsos de carga y descarga que se muestran en la Figura 4.23. Por ejemplo, en la Figura 4.23 las etapas 0 a 17 la batería consume energía para cargarse, esto concuerda con el SOC en la Figura 4.25 en donde se muestra en una pendiente ascendente elevando el SOC de la batería. En las etapas 25 a 96 el SOC muestra una pendiente descendente lo cual concuerda en la Figura 4.23 donde la batería suministra potencia para compensar la demanda de la carga.




Figura 4.25. SOC Batería MCR4 (fuente propia)

4.4. Resultados simulación de convertidores de potencia

El diseño del convertidor Buck-boost para la regulación del voltaje de las fuentes renovables como el panel solar fotovoltaico y el aerogenerador tidal se muestra en la Figura 4.26, el convertidor está conectado entre las terminales del arreglo de paneles y el bus CD que alimenta los motores del vehículo marítimo autónomo, según las necesidades del proyecto el valor nominal del bus CD es 24 voltios, las mediciones que se realizaron al arreglo de paneles producen un mínimo de 19 voltios hasta un máximo de 32 voltios. Por lo cual el convertidor para el panel se diseñó para estos valores de voltaje y una corriente nominal máxima de 20 amperios, obteniendo los siguientes valores de $L=3e-3$, $C=24e-3$, $D=0.53$ y $R=30\Omega$.

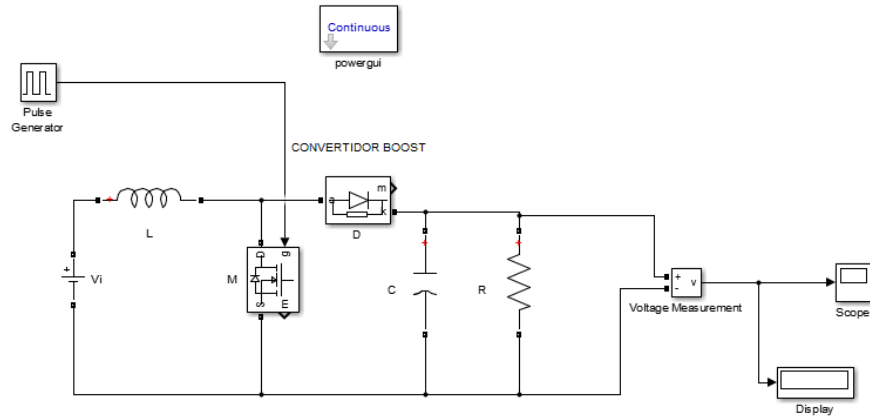


Figura 4.26. diseño de convertidor Buck-boost en lazo abierto

Con los valores de los componentes se procedió a hallar la función de transferencia del convertidor obteniendo el resultado de la Figura 4.27.




Figura 4.27. Función de transferencia en lazo abierto (fuente propia)

Con la función de transferencia se procedió a realizar el análisis de estabilidad. Al ver el diagrama de polos y ceros de la función de transferencia de lazo abierto $G(s)$ definida en la Figura 4.28 se observa que todos los polos del sistema se encuentran al lado izquierdo del plano complejo s , por lo que se puede concluir que el sistema es estable y por lo tanto se puede diseñar un controlador para que el circuito funcione con las especificaciones requeridas.




Figura 4.28. Diagrama de polos y ceros convertidor Buck-boost (fuente propia)

Se procedió a diseñar el controlador PID para el convertidor en cual se obtuvo el resultado mostrado la Figura 4.29.

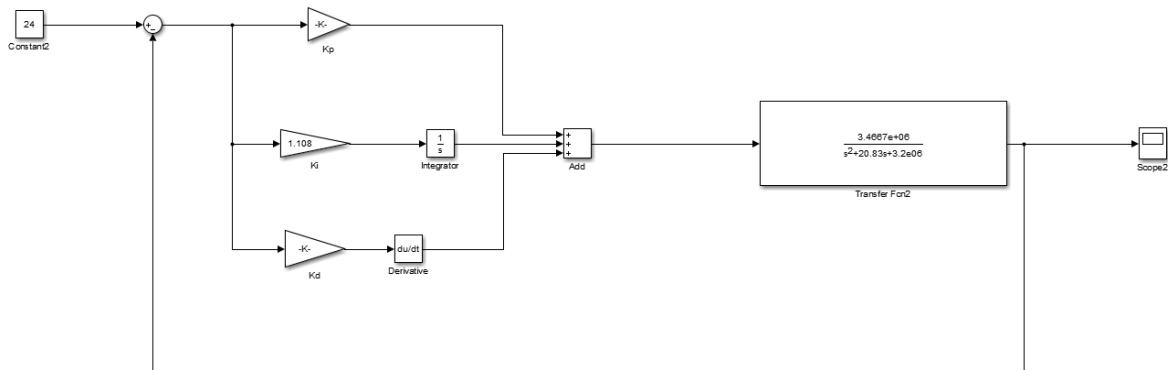


Figura 4.29. Función de transferencia en lazo cerrado (fuente propia)

Con los valores de ganancias del controlador $K_p=0.0090$, $K_i=1.108$ y $K_d=5.7785e-06$ calculados mediante el método de Ziegler-Nichols, se realizó la simulación del circuito en Matlab® como se muestra en la Figura 4.30.

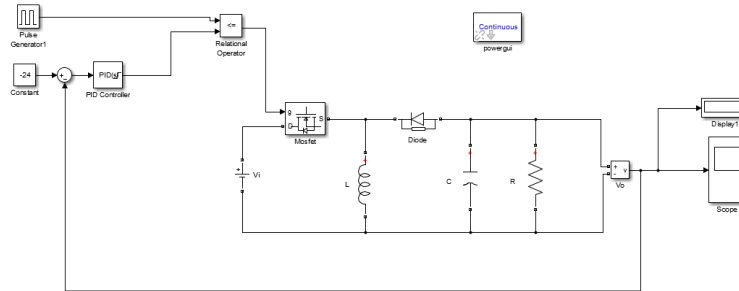


Figura 4.30. Circuito de convertidor en lazo cerrado (fuente propia)





Figura 4.31. Voltaje del convertidor en lazo cerrado (fuente propia)

Para el sistema de almacenamiento se diseña un convertidor Buck-boost bidireccional como se muestra en la Figura 4.32 el voltaje de baja es 12 voltios y el de alta es 24 voltios CD para una corriente de 40 amperios. Con los cálculos realizados se obtuvieron los siguientes resultados $L=3e-3$, $CH=12e-3$, $CL=12e-3$ $D=0.5$, $R1=100\Omega$ y $R2=100\Omega$.






Figura 4.32. Convertidor Buck-boost bidireccional en lazo abierto (fuente propia)

Ya teniendo los parámetros del convertidor se procedió a hallar las funciones de transferencia del voltaje en modo Boost y modo Buck como se muestra en la Figura 4.33.

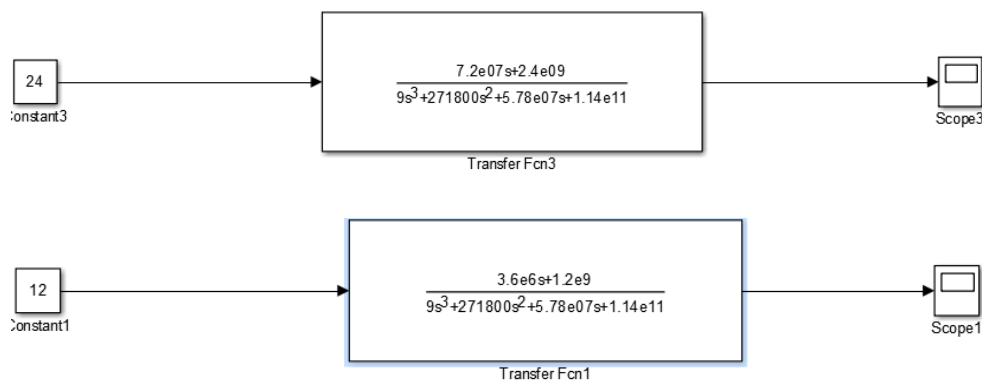



Figura 4.33. Funciones de transferencia en lazo abierto (fuente propia)






Figura 4.34. Salidas de voltaje del convertidor en lazo abierto (fuente propia)

La Figura 4.34 superior muestra la salida de voltaje del convertidor Buck-boost en modo Buck y la Figura 4.34 inferior muestra la salida de voltaje en modo boost. Con las funciones de transferencia encontradas se realiza el análisis gráfico de polos y ceros mostrados en la Figura 4.35 se observa que todos los polos del sistema se encuentran al lado izquierdo del plano complejo s , por lo que se puede concluir que el sistema es estable por lo que se puede proceder a realizar el control del PID del sistema.




Figura 4.35. Diagrama de polos y ceros convertidor Buck-boost bidireccional (fuente propia)

En la Figura 4.37a se muestra el SOC de la batería en modo carga, además en Figura 4.37b se muestran los niveles de corriente oabsorvida por la batería para cargarse y en Figura 4.37c se puede observar el nivel de voltaje necesario para cargar la batería.

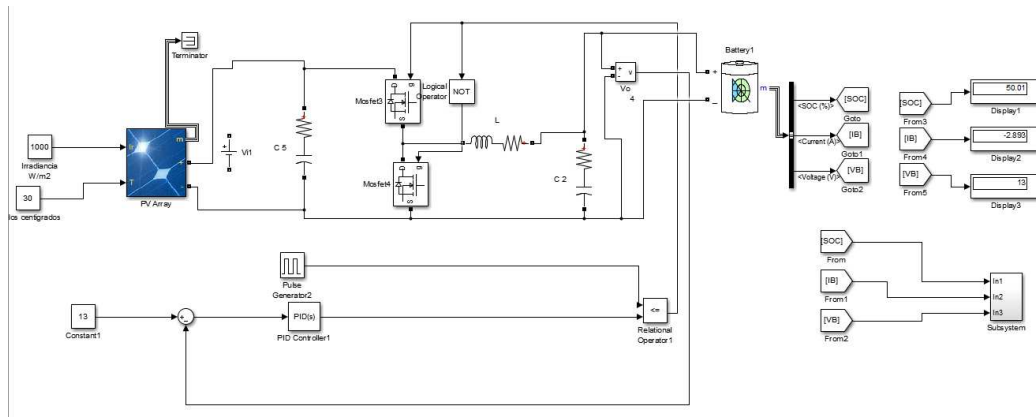


Figura 4.36. Convertidor Buck-boost bidireccional en modo carga (fuente propia)




Figura 4.37. Parámetros de convertidor en modo carga, a) SOC batería b) Corriente de carga c) Voltaje de carga

En la Figura 4.39a se muestra el estado de carga SOC de la batería en modo descarga, en Figura 4.39b se muestra los niveles de corriente de descarga y en Figura 4.39c se muestra el voltaje de descarga.

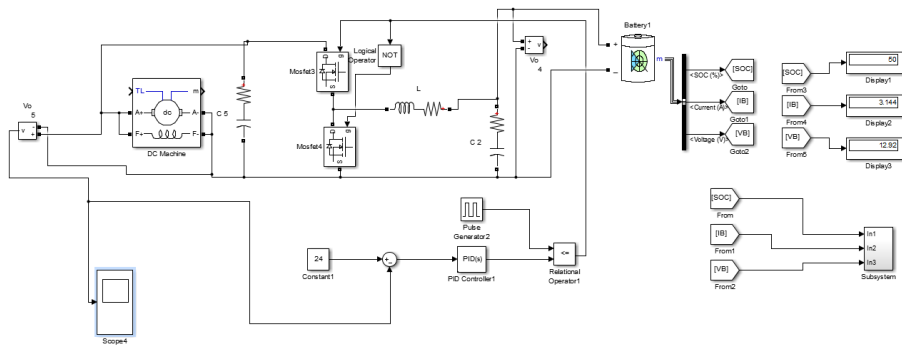


Figura 4.38. Convertidor Buck-boost bidireccional en descarga




Figura 4.39. Parámetros del convertidor en modo descarga, a) SOC batería b) Corriente de descarga c) Voltaje de descarga

Como se mostró en todo este apartado se desarrollaron los modelos matemáticos de los diferentes componentes de la micro-red, estos fueron simulados en Matlab® lo que facilita la resolución del modelo completo del sistema primeramente bajo un modelo de optimización. La optimización de energía se refiere al control terciario de la micro-red.

Los resultados preliminares muestran que el modelo de optimización realiza la gestión de energía del elemento de almacenamiento de manera correcta, cargando el sistema de almacenamiento cuando hay excedente de energía de las fuentes renovables y descargándola cuando las fuentes no son capaces de suplir la energía de los motores del vehículo autónomo marítimo.

Además, se desarrollaron los modelos dinámicos de los convertidores de potencia para que en el siguiente paso se realice la implementación de estos con un control PID para la regulación de

voltaje de la micro-red. La regulación de voltaje en los convertidores y bus CD abarca el control primario y secundario de la micro-red.

4.5. Resultados optimización multiobjetivo

Para esta sección se realiza un análisis de una micro-red ubicada en el edificio CIESOL MCR4 ya descrita anteriormente. En la Figura 4.21 se muestra el esquema de la micro-red. El problema se presenta como un problema de optimización multiobjetivo, en el que se optimizan el costo de energía y la minimización de CO₂.

En el caso de estudio, la simulación de la optimización bioobjetivo se llevó a cabo integrando el MPC en el algoritmo. El problema se resuelve en línea cuando las condiciones de trabajo cambian y permiten actualizar la información de entrada para que el controlador reduzca la incertidumbre. Los resultados correspondientes a los extremos de solución del frente de Pareto se muestran en la Figura 4.40; en este caso, la simulación se realizó con un horizonte de predicción $N = 10$ (2:30 horas) cada etapa de tiempo de 15 minutos. Se empleó el tomador de decisiones para decidir qué solución se adapta mejor a la situación. En la Figura 4.40 a) se muestra la solución elegida por el tomador de decisiones para el problema donde la Ciudad tiene las tasas de contaminación más altas. En este caso el algoritmo prioriza optimizar la función de CO₂, principalmente se utiliza la energía de la red, la cual tiene menores coeficientes de emisión de CO₂ que el generador diésel. Figura 4.40 b) muestra la solución elegida por el tomador de decisiones para la situación en la que la Ciudad tiene índices mínimos de contaminación. El algoritmo prioriza para optimizar los costos de energía y utiliza principalmente la energía del Generador Diesel, que es menos costoso. Los datos sobre los niveles mínimo y máximo de contaminación en la ciudad de Almería han sido facilitados por el Ministerio para la Transición Ecológica y el Reto Demográfico de España (MITECO).

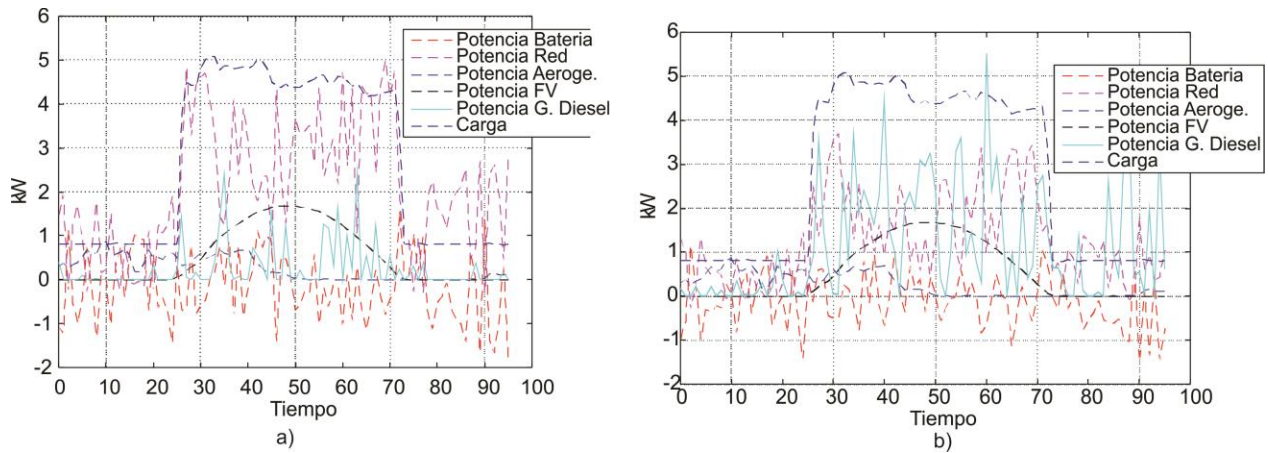


Figura 4.40. Pronóstico de potencia con $N = 10$ (Soluciones de los extremos)

La Figura 4.41 muestra las soluciones elegidas por el decisor al considerar la situación de contaminación de la Ciudad en un nivel intermedio. Puede equilibrarse minimizando los costes energéticos y las emisiones de CO_2 . Se observa en la Figura 4.41 a) que la energía utilizada de la red principal y la energía utilizada del Generador Diesel para alimentar la microrred están equilibradas, tratando de tener el mismo nivel de optimización de costo energético y emisiones de CO_2 . En la Figura 4.41 b), se encuentra un equilibrio al optimizar las dos funciones objetivo de la misma manera.

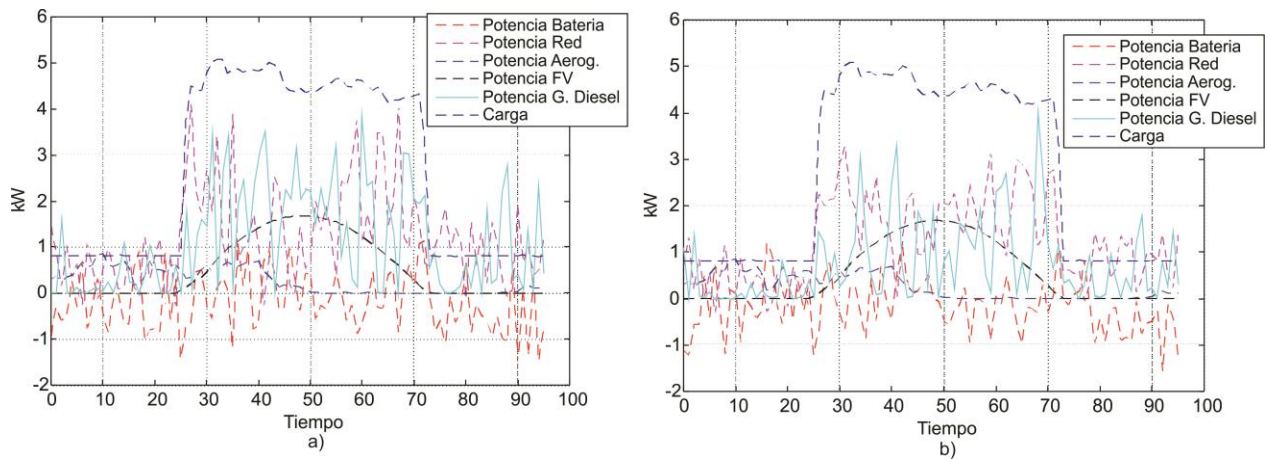


Figura 4.41. Pronóstico de potencia con $N = 10$ (Soluciones nominadas)

En la Figura 4.42 se presentan los tiempos de cálculo utilizados por los algoritmos, primero el algoritmo de un mono objetivo para la optimización de la función objetivo que minimiza el costo de energía. La segunda barra del gráfico muestra el tiempo del algoritmo mono objetivo para la función de optimización de emisiones de CO_2 . La tercera barra muestra el tiempo de cálculo para la solución del problema multiobjetivo. Los resultados muestran que es mejor resolver un

problema multiobjetivo; aunque requiere más tiempo de cálculo, varios problemas de un solo objetivo se resuelven en una sola ejecución. Al realizar la optimización de un solo objetivo, el algoritmo solo encuentra dos soluciones; el tiempo de cálculo utilizado es mucho mayor que el del problema multiobjetivo.




Figura 4.42. Comparación de tiempo de cómputo algoritmos mono objetivo y multiobjetivo

CONCLUSIONES

- Este trabajo presenta un EMS controlado bajo el MPC, incorporando predicciones de radiación solar y velocidad del viento mediante el uso de series de tiempo. Específicamente, utiliza el método de DES para predecir tanto la radiación solar como la velocidad del viento, y datos históricos. Dado que la predicción DES se combina con la MPC, se reduce el coste gastado en energía de la red principal y del generador diésel, ya que la combinación de las predicciones y el control consigue un mejor desempeño en la gestión energética. Los resultados obtenidos han demostrado que la combinación de un MPC con las predicciones DES mejora el rendimiento de las técnicas OPF convencionales, reduciendo el error que introduce la incertidumbre de los sistemas solares fotovoltaicos y aerogeneradores. El beneficio varía según la tarifa de energía eléctrica, el tamaño de los sistemas de almacenamiento y el tamaño de los sistemas solares fotovoltaicos y eólicos pueden ser optimizados. La principal contribución de esta parte del trabajo es la integración de métodos de series de tiempo para la predicción de la radiación solar y la velocidad del viento con MPC.
- También en este trabajo se presenta la resolución de un EMS a través de una optimización multiobjetivo integrada a un MPC que permite el control en tiempo real para su implementación en micro-redes. Combinando el método DES, el MPC y la optimización multiobjetivo, se puede resolver un problema con varios objetivos y tener múltiples soluciones que se pueden adaptar a diferentes escenarios que incluyen otros factores además del técnico y económico. La metodología del tomador de decisiones elige la solución que mejor se adapta en tiempo real al caso particular teniendo una mejor gestión de la energía y las emisiones de CO₂. Además, al resolver un problema multiobjetivo, se obtiene una ventaja en el tiempo de cálculo y la cantidad de soluciones disponibles. Mientras que se resuelve un algoritmo de objetivo único solo podemos obtener una solución que en muchos casos en la vida real no se adapta a las circunstancias. Al integrar la optimización multiobjetivo, MPC y suavizado exponencial doble, y la metodología de tomador de decisiones, se mejora el desempeño del algoritmo que controla el EMS y se reduce el error de control, teniendo una mayor eficiencia energética de la microrred. El principal aporte de este parte del trabajo en el área científica es la integración de optimización multiobjetivo y MPC para su implementación en EMS.

PRODUCTOS

Los resultados del trabajo de tesis se presentan en esta sección, cabe aclarar que algunas actividades que se tenían planeadas para este trabajo no se pudieron llevar a cabo debido al cierre de laboratorio por la emergencia sanitaria COVID-19.

- Simulación de métodos estocásticos para la predicción de radiación solar y velocidad de viento. Se ha logrado la predicción estas variables mediante series de tiempo, obteniendo resultados adecuados mediante método de filtro de Kalman y método de doble exponencial suavizado como se muestra en la sección 4.2.
- Simulación de MPC. Se implementó en simulación un MPC para una micro-red autónoma CD para vehículo marítimo autónomo de CICY, también se implementó MPC para micro-red autónoma CD para vehículo terrestre autónomo de la Universidad de Almería, MPC para micro-red no autónoma con vehículo terrestre autónomo conectado a la red, MPC para micro-red CA para oficinas de CIESOL. Los resultados obtenidos de estas simulaciones se visualizan en la sección 4.3.
- Simulación de optimización multiobjetivo para el MPC que controla el EMS, la optimización multiobjetivo consiste en optimizar dos o más funciones objetivo, en este caso la función de costo económico de la energía y la función de costo ambiental de la producción de energía es decir la función que entrega la cantidad CO_2 emitido al ambiente. Se realiza el análisis de las diferentes soluciones y se encuentra un balance entre el costo económico y costo ambiental y se toma una decisión mediante un tomador de decisiones de ciclo interno.
- Se ha realizado un artículo para congreso el cual fue sometido y aceptado para el Congreso Nacional de Control automático realizado en la ciudad de Puebla del 23 al 26 de octubre de 2019. El cual se muestra en la siguiente imagen.

Energy management system for autonomous vehicle

Luis O. Polanco*, Víctor M. Ramírez¹*
Diego Langarica**

* Centro de Investigación Científica de Yucatán AC., CO 97200 Mérida Yucatán México
¹ corresponding autor: e-mail victor.ramirez@cicy.mx, Tel: 019999428330

** Facultad de Ciencias/ Universidad Autónoma de San Luis Potosí,
San Luis Potosí, México,

Abstract: The present work focuses on forecasting energy generation for an autonomous vehicle. The objective is to find the optimal management of the storage system using a genetic algorithm as an optimization method to be able to use any type of objective function, whether continuous or non-continuous. The energy comes from renewable sources and storage devices. The aim of this paper consists of optimal energy management of the storage system within the hybrid renewable energy system considering known predictions of solar radiation and wind speed for a period, T. The optimization model is solved using a hybrid genetic algorithm with interior point (GA-IP) provided by the optimization toolbox MATLAB®. The case study considers the hybrid renewable energy system with the photovoltaic panels, the wind turbines and the batteries for energy storage. In this test, the power supplied by renewable sources is enough to feed the

- Un segundo artículo fue aceptado en a la revista Applied Sciences como se muestra en la siguiente imagen.



Link de descarga: <https://www.mdpi.com/2076-3417/10/3/1071>

- Un segundo artículo fue aceptado en revista indexada energies de MDPI como se muestra en la siguiente figura.



Link de descarga: <https://www.mdpi.com/1996-1073/14/9/2398>

Un tercer artículo será sometido a la revista Applied Energy. Sobre EMS con control MPC y optimización multiobjetivo.

Multi-objective methodology for micro-grid management: A study case applied to a bioclimatic building.

Luis O. Polanco Vásquez ^a, Víctor M. Ramírez ^{* a}, Kary Thanapalan ^b, Juana López Redondo ^c, José Domingo Álvarez Hervás and José Luis Torres ^c.

^a Unidad de Energía Renovable, Centro de Investigación Científica de Yucatán AC., CO 97205 Mérida, Yucatán, México; e-mail luis.polanco@estudiantes.cicy.mx, victor.ramirez@cicy.mx

^b Engineering and Science, Faculty of Computing, University of South Wales, UK e-mail kary.thanapalan@southwales.ac.uk.

^c University of Almería, Agrifood Campus of International Excellence (ceiA3) CIESOL Joint Centre University of Almería-CIEMAT, CO 04120 Almería (Spain) email: {jlredondo,jhervas,jltmoreno}@ual.es

* Correspondence: victor.ramirez@cicy.mx*

Abstract: In this work, predictive control focuses on solving a multi-objective optimization problem for a microgrid where the cost of energy and the production of CO₂ from different energy sources are simultaneously minimized. Initially, the simulation was carried out for a microgrid in the static mode, where the purpose is to choose other solutions when the conditions change. Still, you do not rerun the optimization problem. A second simulation shows a dynamic optimization problem, in which the online optimization does

PERSPECTIVAS

El trabajo desarrollado proporciona las bases principales para realizar el EMS de la micro-red contenida en el vehículo marítimo autónomo y edificios bioclimáticos. A este respecto, hay varios trabajos que quedan por realizar para una siguiente etapa del proyecto:

- Implementación en micro-red experimental de métodos estocásticos para la predicción de radiación solar y velocidad de viento, MPC para el control de la energía y optimización multiobjetivo para el EMS. Ya teniendo las simulaciones respectivas se puede realizar en la siguiente etapa de implementación en una micro-red experimental.

REFERENCIAS BIBLIOGRÁFICAS

1. Othman M, Anvari-Moghaddam A, Guerrero JM (2017) Hybrid shipboard microgrids: System architectures and energy management aspects. In: IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society. pp 6801–6806
2. Chen C, Xiao L, Duan S, Chen J (2019) Cooperative Optimization of Electric Vehicles in Microgrids Considering Across-Time-and-Space Energy Transmission. *IEEE Trans Ind Electron* 66:1532–1542. <https://doi.org/10.1109/TIE.2017.2784410>
3. Marí L, Nabona N (2015) Renewable Energies in Medium-Term Power Planning. *IEEE Trans Power Syst* 30:88–97. <https://doi.org/10.1109/TPWRS.2014.2328033>
4. Hatziargyriou N, Asano H, Iravani R, Marnay C (2007) Microgrids. *IEEE Power Energy Mag* 5:78–94. <https://doi.org/10.1109/MPAE.2007.376583>
5. Olivares DE, Cañizares CA, Kazerani M (2014) A Centralized Energy Management System for Isolated Microgrids. *IEEE Trans Smart Grid* 5:1864–1875. <https://doi.org/10.1109/TSG.2013.2294187>
6. Rama SS, Rajini M (2021) Energy Management System with a Reduced Sensor for DC Microgrid. In: 2021 Innovations in Energy Management and Renewable Resources(52042). pp 1–6
7. Bidram A, Davoudi A (2012) Hierarchical Structure of Microgrids Control System. *IEEE Trans Smart Grid* 3:1963–1976. <https://doi.org/10.1109/TSG.2012.2197425>
8. Antonio Ruz Hernández J, Suárez Cerda DA, Shelomov E, Villavicencio Ramírez A (2002) Predictive Control Based on an Auto-regressive Neuro-fuzzy Model Applied to the Steam Generator Startup Process at a Fossil Power Plant. In: Computation y systems. pp 430–439
9. Levron Y, Guerrero JM, Beck Y (2013) Optimal Power Flow in Microgrids With Energy Storage. *IEEE Trans Power Syst* 28:3226–3234. <https://doi.org/10.1109/TPWRS.2013.2245925>
10. Gill S, Kockar I, Ault GW (2014) Dynamic Optimal Power Flow for Active Distribution Networks. *IEEE Trans Power Syst* 29:121–131. <https://doi.org/10.1109/TPWRS.2013.2279263>
11. Toman RT, Asumadu JA (2016) Control of a radial micro-grid with unbalanced loads based on a Distributed Model Predictive Control for grid mode operation. In: 2016 IEEE International Conference on Electro Information Technology (EIT). pp 470–

12. Byung Ha Lee, Jin Ah Yang (2015) A study on optimal operation of microgrids considering the uncertainty of renewable generation and load by use of duration curves. In: 2015 IEEE Power Energy Society General Meeting. pp 1–5
13. Kou P, Liang D, Gao L (2017) Distributed EMPC of multiple microgrids for coordinated stochastic energy management. *Appl Energy* 185:939–952. <https://doi.org/https://doi.org/10.1016/j.apenergy.2016.09.092>
14. Mallesham G, Mishra S, Jha AN (2012) Automatic generation control of microgrid using artificial intelligence techniques. In: 2012 IEEE Power and Energy Society General Meeting. pp 1–8
15. Reikard G (2009) Predicting solar radiation at high resolutions: A comparison of time series forecasts. *Sol Energy* 83:342–349. <https://doi.org/https://doi.org/10.1016/j.solener.2008.08.007>
16. Ridha Fethi Mechlouch ABB (2008) A Global Solar Radiation Model for the Design of Solar Energy Systems. *Asian J Sci Res* 1:231–238
17. Zaharim, Azami; Razali, Ahmad Mahir; Gim, Tee Pei; Sopian K (2009) Time Series Analysis of Solar Radiation Data in the Tropics. *Eur J Sci Res* 25:672
18. Wang Y, Cao G, Mao S, Nelms RM (2015) Analysis of solar generation and weather data in smart grid with simultaneous inference of nonlinear time series. In: 2015 IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS). pp 600–605
19. Lukhyswara P, Putranto LM, Ariananda DD (2019) Solar Irradiation Forecasting Uses Time Series Analysis. In: 2019 11th International Conference on Information Technology and Electrical Engineering (ICITEE). pp 1–6
20. Fortuna L., Nunnari G. NS (2016) Time Series Methods. In: Springer C (ed) *Nonlinear Modeling of Solar Radiation and Wind Speed Time Series*, 1st ed. Springer, Cham, pp 1–15
21. Pawlowski A, Guzmán JL, Rodríguez F, et al (2010) Application of time-series methods to disturbance estimation in predictive control problems. In: 2010 IEEE International Symposium on Industrial Electronics. pp 409–414
22. Vadakkoot R, Shah MD, Shrivastava S (2009) Enhanced Moving Average Computation. In: 2009 WRI World Congress on Computer Science and Information Engineering. pp 541–544

23. Jiang W, Fahimi B (2010) Active Current Sharing and Source Management in Fuel Cell–Battery Hybrid Power System. *IEEE Trans Ind Electron* 57:752–761. <https://doi.org/10.1109/TIE.2009.2027249>
24. Chiang SJ, Shieh H, Chen M (2009) Modeling and Control of PV Charger System With SEPIC Converter. *IEEE Trans Ind Electron* 56:4344–4353. <https://doi.org/10.1109/TIE.2008.2005144>
25. Eu-Tjin C, Huat CK, Seng LY (2016) Control strategies in energy storage system for standalone power systems. In: 4th IET Clean Energy and Technology Conference (CEAT 2016). pp 1–8
26. Debnath D, Chatterjee K (2015) Two-Stage Solar Photovoltaic-Based Stand-Alone Scheme Having Battery as Energy Storage Element for Rural Deployment. *IEEE Trans Ind Electron* 62:4148–4157. <https://doi.org/10.1109/TIE.2014.2379584>
27. Ishaque K, Salam Z, Shamsudin A, Amjad M (2012) A direct control based maximum power point tracking method for photovoltaic system under partial shading conditions using particle swarm optimization algorithm. *Appl Energy* 99:414–422. <https://doi.org/https://doi.org/10.1016/j.apenergy.2012.05.026>
28. Wang C, Xiong R, He H, et al (2016) Efficiency analysis of a bidirectional DC/DC converter in a hybrid energy storage system for plug-in hybrid electric vehicles. *Appl Energy* 183:612–622. <https://doi.org/https://doi.org/10.1016/j.apenergy.2016.08.178>
29. Bosso JE, Oggier GG, Garcia GO (2016) Isolated Buck/Boost Bidirectional DC-Three Phase Topology. *IEEE Lat Am Trans* 14:2669–2674. <https://doi.org/10.1109/TLA.2016.7555236>
30. Amir A, Amir A, Selvaraj J, Rahim NA (2016) Study of the MPP tracking algorithms: Focusing the numerical method techniques. *Renew Sustain Energy Rev* 62:350–371. <https://doi.org/https://doi.org/10.1016/j.rser.2016.04.039>
31. Zhiling Liao, Xinbo Ruan (2009) A novel power management control strategy for stand-alone photovoltaic power system. In: 2009 IEEE 6th International Power Electronics and Motion Control Conference. pp 445–449
32. Del-Rio-Rivera F, Ramírez-Rivera VM, Donaire A, Ferguson J (2020) Robust Trajectory Tracking Control for Fully Actuated Marine Surface Vehicle. *IEEE Access* 8:223897–223904. <https://doi.org/10.1109/ACCESS.2020.3042091>
33. Fioriti D, Lutzemberger G, Poli D, et al (2021) Coupling economic multi-objective optimization and multiple design options: A business-oriented approach to size an

- off-grid hybrid microgrid. *Int J Electr Power Energy Syst* 127:106686. <https://doi.org/https://doi.org/10.1016/j.ijepes.2020.106686>
34. Fioriti D, Pintus S, Lutzemberger G, Poli D (2020) Economic multi-objective approach to design off-grid microgrids: A support for business decision making. *Renew Energy* 159:693–704. <https://doi.org/https://doi.org/10.1016/j.renene.2020.05.154>
 35. Boucekara HRA-H, Shahriar MS, Javaid MS, et al (2021) Multi-Objective Optimization of a Hybrid Nanogrid/Microgrid: Application to Desert Camps in Hafr Al-Batin. *Energies* 14:. <https://doi.org/10.3390/en14051245>
 36. Bukar AL, Tan CW, Yiew LK, et al (2020) A rule-based energy management scheme for long-term optimal capacity planning of grid-independent microgrid optimized by multi-objective grasshopper optimization algorithm. *Energy Convers Manag* 221:113161. <https://doi.org/10.1016/j.enconman.2020.113161>
 37. Zhang Q, Ding J, Shen W, et al (2020) Multiobjective Particle Swarm Optimization for Microgrids Pareto Optimization Dispatch. *Math Probl Eng* 2020:5695917. <https://doi.org/10.1155/2020/5695917>
 38. Li X, Li Z (2017) Micro-grid resource allocation based on multi-objective optimization in cloud platform. In: 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS). pp 509–512
 39. Hong B, Zheng Z (2016) Stochastic multi-objective dynamic optimal dispatch for combined heat and power microgrid. In: 2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). pp 2369–2373
 40. Wang L, Yeh T, Lee W, Chen Z (2009) Benefit Evaluation of Wind Turbine Generators in Wind Farms Using Capacity-Factor Analysis and Economic-Cost Methods. *IEEE Trans Power Syst* 24:692–704. <https://doi.org/10.1109/TPWRS.2009.2016519>
 41. Bellini A, Bifaretti S, Iacovone V, Cornaro C (2009) Simplified model of a photovoltaic module. In: 2009 Applied Electronics. pp 47–51
 42. Wp S (2018) SLA-M 300 Wp Silfab Solar Inc, Data sheet module Silfab
 43. González I, Sánchez A, Langarica-Cordoba D, et al (2021) A PI + Sliding-Mode Controller Based on the Discontinuous Conduction Mode for an Unidirectional Buck–Boost Converter with Electric Vehicle Applications. *Energies* 14:. <https://doi.org/10.3390/en14206785>

44. K. Charles, N. Matthew OS (2004) Fundamentos de circuitos eléctricos
45. Ramirez V, Ortega R, Griñó R, et al (2012) Theory and experimental results of two dynamic energy routers. In: 2012 American Control Conference (ACC). pp 2128–2133
46. Miguel Ángel Ramírez Basalo (2012) Diseño de un modelo informático para la estimación de la energía generada en el vehículo solar Aníbal. Universidad Politécnica de Cartagena
47. Dev S, AlSkaif T, Hossari M, et al (2018) Solar Irradiance Forecasting Using Triple Exponential Smoothing. In: 2018 International Conference on Smart Energy Systems and Technologies (SEST). pp 1–6
48. Welch G, Bishop G (1995) An Introduction to the Kalman Filter. University of North Carolina at Chapel Hill, USA
49. Luan H. Tran (2017) Application of Kalman Filtering for PV Power Prediction in Short-Term Economic Dispatch. College of Engineering and Mineral Resources at West Virginia University
50. Gulin M, Matuško J, Vašak M (2015) Stochastic model predictive control for optimal economic operation of a residential DC microgrid. In: 2015 IEEE International Conference on Industrial Technology (ICIT). pp 505–510
51. Tabar VS, Jirdehi MA, Hemmati R (2017) Energy management in microgrid based on the multi objective stochastic programming incorporating portable renewable energy resource as demand response option. *Energy* 118:827–839. <https://doi.org/10.1016/j.energy.2016.10.113>
52. Meiqin M, Meihong J, Wei D, Chang L (2010) Multi-objective economic dispatch model for a microgrid considering reliability. In: The 2nd International Symposium on Power Electronics for Distributed Generation Systems. pp 993–998
53. e Silva DP, Félix Salles JL, Fardin JF, Rocha Pereira MM (2020) Management of an island and grid-connected microgrid using hybrid economic model predictive control with weather data. *Appl Energy* 278:115581. <https://doi.org/10.1016/j.apenergy.2020.115581>
54. Vermuyten E, Meert P, Wolfs V, Willems P (2018) Combining Model Predictive Control with a Reduced Genetic Algorithm for Real-Time Flood Control. *J Water Resour Plan Manag* 144:. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000859](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000859)
55. Reynolds J, Rezgui Y, Kwan A, Piriou S (2018) A zone-level, building energy

- optimisation combining an artificial neural network, a genetic algorithm, and model predictive control. *Energy* 151:729–739.
<https://doi.org/https://doi.org/10.1016/j.energy.2018.03.113>
56. Sarimveis H, Bafas G (2003) Fuzzy model predictive control of non-linear processes using genetic algorithms. *Fuzzy Sets Syst* 139:59–80.
[https://doi.org/https://doi.org/10.1016/S0165-0114\(02\)00506-7](https://doi.org/https://doi.org/10.1016/S0165-0114(02)00506-7)
 57. Clarke WC, Manzie C, Brear MJ (2016) An economic MPC approach to microgrid control. In: 2016 Australian Control Conference (AuCC). pp 276–281
 58. Batiyah S, Zohrabi N, Abdelwahed S, Sharma R (2018) An MPC-Based Power Management of a PV/Battery System in an Islanded DC Microgrid. In: 2018 IEEE Transportation Electrification Conference and Expo (ITEC). pp 231–236
 59. Camacho EF, Bordons C (2010) Control Predictivo: Pasado, Presente y Futuro. *Rev Iberoam Automática e Informática Ind* 1:5–28
 60. Romero-Quete D, Garcia JR (2019) An affine arithmetic-model predictive control approach for optimal economic dispatch of combined heat and power microgrids. *Appl Energy* 242:1436–1447.
<https://doi.org/https://doi.org/10.1016/j.apenergy.2019.03.159>
 61. Camacho EF, Bordons C (2007) *Model Predictive control*. Springer London, London
 62. Mayne DQ, Rawlings JB, Rao C V, Sokaert POM (2000) Constrained model predictive control: Stability and optimality. *Automatica* 36:789–814.
[https://doi.org/https://doi.org/10.1016/S0005-1098\(99\)00214-9](https://doi.org/https://doi.org/10.1016/S0005-1098(99)00214-9)
 63. Leet JHS (2003) Worst-case Formulations of Model Predictive Control for Systems with Bounded Parameters *
 64. Bemporad A, Morari M, Dua V, Pistikopoulos EN (2002) The explicit linear quadratic regulator for constrained systems. *Automatica* 38:3–20.
[https://doi.org/https://doi.org/10.1016/S0005-1098\(01\)00174-1](https://doi.org/https://doi.org/10.1016/S0005-1098(01)00174-1)
 65. Mathworks C (2014) Optimization Toolbox™ User ' s Guide R 2014 b.
http://www.mathworks.com/help/pdf_doc/optim/optim_tb.pdf
 66. Michalewicz Z (1996) *Genetic Algorithms + Data Structures = Evolution Programs*. Springer Berlin Heidelberg, Berlin, Heidelberg
 67. Goldberg DE (1989) *Genetic Algorithms in Search, Optimization and Machine Learning*, 1st ed. Addison-Wesley Longman Publishing Co., Inc., USA
 68. Holland JH (1992) *Adaptation in Natural and Artificial Systems: An Introductory*

Analysis with Applications to Biology, Control and Artificial Intelligence. MIT Press, Cambridge, MA, USA

69. Houck C, Joines J, Kay M (1998) A Genetic Algorithm for Function Optimization: A MATLAB implementation. NCSU/IE-TR-95-09 North Carolina State Univ Raleigh, NC, USA 22:
70. Joines JA, Houck CR (1994) On the use of non-stationary penalty functions to solve nonlinear constrained optimization problems with GA's. Proc First IEEE Conf Evol Comput IEEE World Congr Comput Intell 579–584 vol.2
71. Roijers DM, Whiteson S (2017) Multi-Objective Decision Making. Synth Lect Artif Intell Mach Learn 11:1–129.
<https://doi.org/10.2200/S00765ED1V01Y201704AIM034>

ANEXO 1

En este apéndice se muestran los parámetros de los componentes de la micro-red MCR1 del caso de estudio, los cuales son los siguientes

Datos de componentes de micro-red MCR1

$$P_{aerogenerador} = 1000 \text{ Watt} \quad -100 < Q_{wind \text{ aerogenerador}} > 100 \text{Var}$$

$$P_{bat} = 200 \text{ Watt}$$

$$P_{pV} = 200 \text{ Watt}$$

Coefficientes de costo de red principal

$$a = 0.014, \quad b = 0.020, \quad c = 0.0060$$

Limites de voltaje

$$Min = 0.95 \text{ pu}, \quad Max = 1.05,$$

Parámetros de los componentes de la micro-red MCR2 del caso de estudio, los cuales son los siguientes

Datos de componentes de micro-red MCR2

$$P_{aerogenerador} = 0.5 \text{ kWatt} \quad -50 < Q_{wind \text{ aerogenerador}} > 50 \text{Var}$$

$$P_{bat} = 2 \text{ kWatt}$$

$$P_{pV} = 2 \text{ kWatt}$$

Coefficientes de costo de red principal

$$a = 0.014, \quad b = 0.020, \quad c = 0.0060$$

Limites de voltaje

$$Min = 0.95 \text{ pu}, \quad Max = 1.05,$$

Parámetros de los componentes de la micro-red MCR3 del caso de estudio, los cuales son los siguientes

Datos de componentes de micro-red MCR3

$$P_{aerogenerador} = 1 \text{ kWatt} \quad -0.10 < Q_{wind \text{ aerogenerador}} > 0.10 \text{ kVar}$$

$$P_{bat} = 3 \text{ kWatt}$$

$$P_{pV} = 2 \text{ kWatt}$$

$$P_{red} = \text{inf.}$$

Coefficientes de costo de red principal

$$a = 0.014, \quad b = 0.020, \quad c = 0.0060$$

Limites de voltaje

$$Min = 0.95 \text{ pu}, \quad Max = 1.05,$$

Parámetros de los componentes de la micro-red MCR4 del caso de estudio, los cuales son los siguientes

Datos de componentes de micro-red MCR4

$$P_{aerogenerador} = 1kWatt \quad -0.10 < Q_{wind \text{ aerogenerador}} > 0.10kVar$$

$$P_{bat} = 2 \text{ kWatt}$$

$$P_{PV} = 2 \text{ kWatt}$$

$$P_{red} = \text{inf.}$$

$$P_{Gdiesel} = 2kWatt$$

Limites de voltaje

$$Min = 0.95 \text{ pu}, \quad Max = 1.05,$$