

Modelado y Simulación de Sistemas de Control Predictivos para la Generación Eléctrica en Redes Inteligentes

Checa, Gabriel^{1,*}; Cabrera, Ana²; Sampietro, José²; Valencia, Nakira³; Ulloa, Raúl³

¹Pontificia Universidad Católica del Ecuador Sede Esmeraldas, Departamento de Postgrado, Esmeraldas, Ecuador

²Universidad Tecnológica ECOTEC, Facultad de Ingeniería, arquitectura y ciencias de la naturaleza, Guayas, Ecuador

³Universidad Técnica Luis Vargas Torres, Facultad de Ingenierías, Esmeraldas, Ecuador

Resumen: Las redes eléctricas inteligentes (RI) son reconocidas como un componente tecnológico fundamental para enfrentar el aumento de la demanda energética, mejorando la confiabilidad y sostenibilidad de los sistemas eléctricos. El presente estudio incluye en la RI elementos de almacenamiento que permiten disminuir la potencia suministrada por las fuentes de generación principales durante las horas de mayor demanda. Esto asegura que la demanda siempre se cubra y a la vez que se opera dentro de los rangos de mayor eficiencia. Se propone el uso de la herramienta de cómputo Matlab, mediante el Toolbox de YALMIP, enfocado en la modelización y resolución de problemas de optimización y control, para desarrollar una estrategia de Control Predictivo de Modelos (MPC) que gestione los recursos energéticos de una RI y permita cumplir la demanda de energía, y que respete las restricciones del controlador. Se destaca el uso de tres fuentes de generación, dentro de las cuales dos son consideradas principales, siendo las mismas: la energía eólica y energía solar y la tercera es considerada como un sistema de almacenamiento conformado por baterías. Los resultados indican que al incorporar un MPC, podremos disminuir los costes de generación, derivados del maximizar la vida útil de los elementos y del almacenar energía durante el periodo de producción.

Palabras clave: Redes inteligentes, respuesta a la demanda, control predictivo por modelos

Modeling and Simulation of Predictive Control Systems for Power Generation in Smart Grids

Abstract: Smart Grids (SG) are recognized as a fundamental technological component to address the increase in energy demand, improving the reliability and sustainability of electricity systems. The present study includes in the SG storage elements that allow decreasing the power delivered by the main generation sources during peak demand hours. This ensures that the demand is always met while operating within the highest efficiency ranges. The use of the Matlab computational tool, through the YALMIP Toolbox, focused on modeling and solving optimization and control problems, is proposed to develop a Model Predictive Control (MPC) strategy that manages the energy resources of an SG and allows meeting the energy demand, and respects the controller constraints. The use of three generation sources is highlighted, two of which are considered to be the main ones, being wind and solar energy, and the third one is considered to be a storage system made up of batteries. The results indicate that by incorporating an MPC, we will be able to reduce generation costs, derived from maximizing the useful life of the elements and storing energy during the production period.

Keywords: Smart Grids, Demand Response, Model Predictive Control

1. INTRODUCCIÓN

En la actualidad, se observa una tendencia hacia la integración de centrales eléctricas tradicionales que utilizan combustibles fósiles con otras tecnologías, incluyendo fuentes de energía renovable (Arce et al., 2014). Con el incremento de demanda de energía en todo el mundo, se buscan maneras de satisfacer estas necesidades mediante fuentes de energía que no emitan

gases contaminantes basadas en energías renovables (Jia & Sun, 2017). Esta necesidad de satisfacer de forma sostenible aquella creciente demanda de energía requiere redes eléctricas de distribución con energías activas, con potencial de flujo de energía bidireccional (Ma et al., 2019). Esto plantea el desafío significativo de integrar plantas de generación de energía renovable y convencional, coordinándolas como un sistema único (Jia & Sun, 2017). Por consiguiente, los países han

*gabrielchecha90@gmail.com

Recibido: 03/05/2024

Aceptado: 23/09/2024

Publicado en línea: 30/11/2024

10.33333/rp.vol54n2.01

CC 4.0

dirigido parte de sus esfuerzos hacia la formulación de planes estratégicos y la adopción de prácticas tecnológicas innovadoras con el objetivo de promover el ahorro de energía (Montoya et al., 2015).

Así también, la integración de los diversos componentes de las SG, como los sistemas de almacenamiento y fuentes primarias con los sistemas de generación actuales, se considera un desafío debido a la gestión de la potencia entregada en los distintos instantes de la demanda (Velasquez et al., 2021). Las SG se consideran un importante apoyo tecnológico para que la respuesta ante la demanda fluctuante ofrezca una mayor fiabilidad y la sostenibilidad del sistema eléctrico (Halvgaard et al., 2016). En este sentido, Freire et al. (2020) mencionan que las fuentes de energía renovable gozan de una amplia aceptación, ya que representan una alternativa de producción energética que difiere de las fuentes tradicionales y no causa contaminación ambiental. Por tanto, las SG se perfilan como la tendencia y la próxima generación en el ámbito de las redes eléctricas.

Estudios recientes como el realizado por Kirn Kumar. et al. (2020) evalúan el papel de las unidades eólicas en el funcionamiento óptimo de las redes inteligentes teniendo en cuenta el costo y las pérdidas de energía. Mientras que, Ahmad & Khan (2020) estudian el impacto de los paneles solares en la gestión energética de las SG y concluyen que las fuentes solares son fuentes de energía limpias y sostenibles. Algunas características de estas fuentes de generación son ampliamente estudiadas en Abril et al. (2021) y Basit et al. (2024), mismas que se orientan al flujo de potencia proporcionado, su capacidad energética, curvas de eficiencia y problemas de operación recurrentes dependiendo de la superficie en la que se instalen. También, se evalúa su integración en sistemas de distribución orientados a cubrir demandas de sistemas puntuales.

En sistemas de control modernos, se reconoce el Control Predictivo basado en Modelos (MPC, por sus siglas en inglés) como una solución ampliamente adoptada. Esto se debe a que emplea un modelo de espacio de estado del sistema para anticipar las trayectorias, como señalan Oshnoei et al. (2021). El comportamiento futuro del sistema es una cuestión fundamental para desarrollar modelos basados en la previsión de la demanda y la producción de energía renovable, y el MPC se basa en esto (Shi et al., 2021). No obstante, se menciona que la respuesta a la demanda es un factor importante que contribuye a lograr equilibrar generación y demanda en las SG. Es por ello que, el uso de procedimientos que optimicen la capacidad de tratar con las limitaciones del sistema en cada tiempo de muestreo (Freire et al., 2020).

Dado que el MPC se percibe como una solución para los desafíos en sistemas de control y las SG como la nueva generación de redes eléctricas, el objetivo principal de este estudio es desarrollar un MPC para la generación de energía en SG utilizando para su simulación y modelado la herramienta YALMIP de Matlab. Existen distintas herramientas para la gestión de control, no obstante, se ha escogido la herramienta indicada debido a que permite la introducción de las matrices de control y de estados de forma sencilla, además de considerar las restricciones de control y

operacionales como desigualdades, como se lo muestra en (Poursmaeil et al., 2021; Ravat et al., 2021). Asimismo, puede utilizar una amplia variedad de SOLVERS para el problema de control, como CPLEX (Interactive Optimizer of IBM), QP (Convex quadratic objective function, siglas en inglés), entre otros. Esto indica la robustez de la herramienta, que se ha usado en estudios anteriores como Vardhan et al. (2022) y Yelisetti et al. (2020).

El propósito es mejorar la eficiencia en la operación de las fuentes de generación, incluyendo restricciones mediante ecuaciones de coste multifunción y el controlador MPC, que ayuda a preservar la vida útil de los componentes. Por ejemplo, se limita el Estado de Carga de la Batería (SOC, siglas en inglés) hasta un 80 %, y la descarga de la misma hasta en 30 %. Además, permite la operación suave de los elementos de manera que no se produzcan picos de potencia que provoquen un desbalance en el sistema de energía que se simula como carga, como lo muestran Kim et al. (2022) y Sun et al. (2023).

Esto se traduce en un mejor dimensionamiento que minimiza el costo de las baterías, paneles y demás elementos a implementar, además de reducir los costos de operación y de mantenimiento. De esta manera, se logra operar los sistemas de generación de manera más económica y eficiente, reduciendo los picos de potencia entregada y restableciendo el sistema de manera más rápida y eficaz en caso de fallos.

La presente investigación se estructura en 4 secciones. La sección 2 presenta los componentes de la SG, y el diseño matemático del MPC. La sección 3 compara la operación de los sistemas de generación usando el sistema de control predictivo con la carga simulada. Finalmente, las conclusiones y los trabajos futuros del estudio se describen en la Sección 4.

2. METODOLOGÍA

2.1 Aspectos generales de la investigación

En lineamientos generales, este trabajo se basa en cumplir la demanda de un perfil de potencia mediante el despacho óptimo de diversas fuentes de generación. Las fuentes escogidas son la energía solar y eólica, y como fuente de almacenamiento las baterías. Esta configuración se realiza debido a las características de densidad de potencia y energía de cada uno de los elementos. El controlador permitirá operar en puntos de eficiencia y realizar acciones para preservar la vida útil de los componentes, cumpliendo el despacho programado. Además, el controlador minimizará una función de coste general que se subdivide en varias funciones, como se muestra en trabajos como Del Real et al. (2014), Halvgaard et al. (2016), Segovia et al., (2019) y Shi et al. (2019). El problema de control se orienta hacia el cumplimiento de perfiles de potencia y energía, como se muestra en Del Real et al. (2014) y Hu et al. (2021). En el presente trabajo, se explicará posteriormente cual será la función de coste y como se constituirá.

Igualmente, se efectuaron simulaciones para diferentes circunstancias de demanda de energía con el fin de probar que el controlador MPC responde de manera adecuada en cada instante de generación y asegura el despacho, inclusive si los

picos de demanda sobrepasan la potencia máxima de una de las fuentes primarias.

Para llevar a cabo la investigación, en primer lugar, se estableció la estructura y dimensiones de la SG, en función de la potencia de demanda. Posteriormente, se definió el modelo de los componentes que la conforman como el sistema eólico, fotovoltaico y de la batería, con base en la potencia que brinda cada elemento al bus de potencia general. Esta distribución se puede observar en la Figura 1.

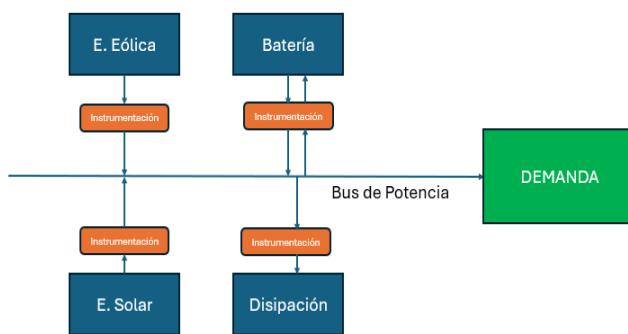


Figura 1. Esquema de componentes de la SG

Una vez definidos los elementos, se procede a realizar la formulación matemática que será explicada desde el apartado 2.2, incluyendo la del controlador MPC. Para poder simular y asegurar de que la demanda se cumple, se generó un perfil de demanda. Para la obtención del perfil de demanda se procedió obtener datos de consumo energético en potencia de un grupo electrógeno de Motores de Combustión Interna (MCI). Este grupo de 12 motores de 12 MW de potencia, entrega potencia para el Sistema Nacional Interconectado del Ecuador (SNI), dependiendo de la demanda. Los MCI entregan potencia de manera rápida y suelen apagarse cuando pasan los picos de carga, por lo que en la sección 3.1 veremos la forma del perfil resultante. Estos datos fueron llevados hasta el Software Matlab para poder generar la curva respectiva, a la cual se le añadió ruido blanco.

Finalmente, mediante la herramienta de software Matlab con su librería Yalmip, se llevaron a cabo las simulaciones. El propósito era anticipar las variaciones de la demanda, con el fin de cumplir las restricciones y demostrar la eficiencia y confiabilidad del sistema. Aunque la gestión de redes inteligentes es tratada en muchos estudios, el aporte de este trabajo es la construcción del controlador MPC, con base en funciones individuales de coste que permiten manejar diversos parámetros de operación en cada una de ellas, como por ejemplo representar los costes operacionales, la vida útil de los elementos y demás. Aparte de realizar un modelo de potencias, en el cual es intuitiva la visualización de la oferta versus la demanda de potencia. Una vez que se culmine la etapa de modelamiento, se incluirá una gráfica del algoritmo.

2.2 Modelo de la red inteligente

Se diseñó la SG con varios componentes como fuentes de flujo, enlaces, nodos y almacenamiento. En este trabajo, se consideró la SG compuesta por n_s fuentes de energía, n_x

elementos de almacenamiento, n_q buses de conexión y n_d cargas (Nassourou et al., 2018). Excepto las fuentes y los elementos de almacenamiento, todo lo demás será considerado como instrumentación. La ecuación matemática de cada componente se proporciona a continuación. Los elementos almacenadores de energía y la generación eléctrica se consideran fuentes de flujo, que proporcionan energía a las cargas. Las fuentes de flujo deben estar restringidas ya que sus producciones están limitadas según se expone en la Ecuación 1:

$$P^{min} \leq P(k) \leq P^{max} \quad (1)$$

donde $P(k)$ es la energía suministrada en el momento k , P^{min} es el límite inferior (normalmente fijado en cero), y P^{max} es el límite superior determinado por la energía instalada o basada en la restricción de la capacidad energética neta. Algunos elementos de la fuente de flujo, como las fuentes de energía renovable, tienen un límite superior de potencia adicional dependiente del tiempo y determinado por la disponibilidad del recurso en base al instante k . Entonces, la Ecuación 1 se puede reescribir como se especifica en la Ecuación 2:

$$P^{min} \leq P(k) \leq P^+(k) \leq P^{max} \quad (2)$$

donde $P^+(k)$ es el perfil de generación de energía máxima en el instante k . Las unidades de flujo (enlaces activos) se utilizan para conectar las fuentes de energía de los elementos de enlace a la red. Estas unidades pueden cambiar la energía de corriente continua (DC) o de corriente alterna (AC) a AC o DC, por ejemplo, mediante inversores o rectificadores (Nassourou et al., 2018). En este estudio, todo esto queda representado por la instrumentación en la Figura 1. También, se pueden adaptar los valores de tensión de las fuentes de energía para que se ajusten a los estándares de tensión de la red de conexión mediante convertidores. De igual manera, las unidades de control de flujo seleccionan entre los límites establecidos en la Ecuación 1 la energía producida por su fuente de alimentación asociada.

Además, la salida del controlador de energía $u_{out}(k)$ expresada en la Ecuación 3, viene dada por la potencia suministrada por la fuente de flujo multiplicada por un índice de rendimiento eléctrico η :

$$u_{out}(k) = \eta P(k) \quad (3)$$

Entonces, considerando la Ecuación 3 en los límites de potencia definidos por las Ecuaciones 1 y 2, se logran obtener las Ecuaciones 4 y 5 como dos formas de expresar los límites de potencia;

$$\eta P^{min} \leq u_{out}(k) \leq \eta P^{max} \quad (4)$$

$$\eta P^{min} \leq u_{out}(k) \leq P^+(k) \leq \eta P^{max} \quad (5)$$

Por otro lado, un elemento de tratamiento del flujo que no aumenta ni disminuye la energía entrante se denomina enlace pasivo. Estos son, en esencia, componentes encargados de reenviar la energía entrante a otros componentes de la red. En

algunos casos, podrían ser tan simples como interruptores o líneas de transmisión cortas.

Dado que consumen energía que fluye, los elementos sumideros representan la demanda de carga. En la Ecuación 6, se hace referencia a las demandas de carga, denominadas $d(k)$ (en el momento k), y están limitadas por la capacidad energética de la conexión de red o por las demandas máximas establecidas por los contratos de los usuarios.

$$d^{min} \leq d(k) \leq d^{max} \quad (6)$$

donde d^{min} y d^{max} son los límites inferior y superior de las demandas.

2.3 Modelo de la batería

El diseño del modelo de almacenamiento se llevó a cabo considerando las aportaciones de otros estudios, como el de Wenzhong (2005), quien señala que el valor de la resistencia desempeña un papel crucial en las condiciones de carga y descarga. Además, se establece que tanto la resistencia como el voltaje en circuito abierto son funciones no lineales del SOC. En consecuencia, el modelo de la batería se deriva del circuito equivalente, graficado en la Figura 2. Para establecer el modelo de la batería aplicamos la Ley de Kirchhoff, según se especifica en la Ecuación 7:

$$u_b(t) = u_{oc}(t) - r_i(t)r_b(t) \quad (7)$$

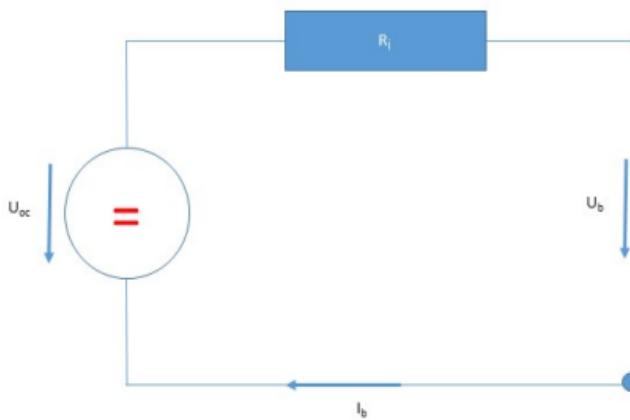


Figura 2. Circuito equivalente de la batería

donde u_b es la tensión del circuito, u_{oc} la tensión en circuito abierto, r_i la resistencia interna y i_b la intensidad en los terminales del circuito.

En la Ecuación 8, se representa la tensión del circuito abierto como la carga en la batería expresada en forma de función y la parametrización de esta función descrita por Carignano et al. (2019).

$$u_{oc}(t) = k_2 SOC(t) + k_1 \quad (8)$$

donde los coeficientes k_1 y k_2 dependen únicamente del diseño y número de baterías y no de las variables de funcionamiento, por lo que se puede suponer que son constantes en el tiempo. La resistencia interna r_i es la suma de

varios fenómenos dentro de la batería y también puede expresarse en función del estado de carga según se especifica en la Ecuación 9:

$$r_i(t) = k_4 SOC(t) + k_3 \quad (9)$$

donde los coeficientes k_3 y k_4 son característicos de la batería. Existen estudios como el de Johnson (2002), que, además de presentar dicha formulación, distinguen entre los aspectos de carga y descarga en el modelo. Un aspecto a tener en cuenta en este modelo es que la resistencia es constante e independiente de la corriente en la batería.

Bajo este contexto y conociendo la intensidad i_b de la batería, se la determinó como se especifica en la Ecuación 10:

$$i_b(t) = \frac{p_b(t)}{u_b(t)} \quad (10)$$

donde $p_b(t)$ es la potencia de la batería. Entonces, a partir de las Ecuaciones 1, 2, 3 y 4 se obtuvo la siguiente expresión según se indica en la Ecuación 11:

$$\begin{aligned} u_b^2(t) - (k_2 SOC(t) + k_1)u_b(t) \\ + p_b(t)(k_4 SOC(t) + k_3) = 0 \end{aligned} \quad (11)$$

El voltaje de la batería se obtiene a partir de la Ecuación 12:

$$\begin{aligned} u_b(t) = \frac{k_2 SOC(t) + k_1}{2} \\ + \sqrt{\frac{k_2 SOC(t) + k_1}{4} - [p_b(t)(k_4 SOC(t) + k_3)]} \end{aligned} \quad (12)$$

Dependiendo de la tensión y la corriente requeridas según las características de las baterías usadas, un grupo de baterías se puede conectar entre sí de tres formas: serie, paralelo o mixta serie-paralelo. Así también, en función de las celdas a utilizar, la Ecuación 12 puede representarse en base a r_i y u_{oc} , según se especifica en la Ecuación 13, lo cual simplifica lo obtenido con la siguiente expresión:

$$u_b(t) = \frac{u_{oc}(t)}{2} + \sqrt{\frac{u_{oc}(t)}{4} - (p_b(t)r_i(t))} \quad (13)$$

donde n_{batp} es el número de celdas en paralelo y n_{bats} es el número de celdas en serie a utilizar.

De este modo, las variables, u_b y u_{oc} están vinculadas al proceso de carga experimentado por la batería, que para su representación requiere de un parámetro específico. La obtención de dicho parámetro depende del número de celdas utilizadas. La Ecuación 10 puede ser reescrita para reflejar este proceso de cargo lo que resulta en la Ecuación 14 que se muestra a continuación:

$$i_b(t) = \frac{p_{bat}(t)}{u_b(t)c_{bat}n_{batp}} \quad (14)$$

Además, se deben considerar las restricciones de carga y descarga de potencia de la batería, las cuales se determinan a partir de las Ecuaciones 15 y 16, en donde p_{cb} es la potencia de carga y p_{db} es la potencia de descarga.

$$p_{cb}(SOC) = -\frac{n_{bats}u_{cmax}^2 - u_{oc}(t)u_{cmax}}{r_i(t)} n_{batp} \quad (15)$$

$$p_{db}(SOC) = \frac{-n_{bats}u_b(t)^2 + u_{oc}(t)u_{cmin}}{r_i(t)} n_{batp} \quad (16)$$

Por otro lado, la Tabla 1 muestra los parámetros que se utilizarán para el modelo de la batería los cuales se obtuvieron de (Carignano et al., 2016).

Tabla 1. Parámetros de la batería

Parámetro	Valor
k_1	1.2 (V)
k_2	0.21 (V)
u_{cmax}	1.55 (V)
u_{cmin}	0.55 (V)
r_i	2.2 (mΩ)
SOC_{max}	0.9
SOC_{min}	0.3
E_{max}	46 (Wh/Kg)
P_{max}	1300 (W/Kg)
T	-20 A 50 (°C)

2.4 Modelo del sistema de generación fotovoltaico

Los modelos matemáticos generales de celdas solares se han estudiado durante varios años, inclusive en trabajos como el de Phang et al. (1984), se muestran que la tecnología se empieza a estudiar hace muchos años atrás. Dentro de los sistemas fotovoltaicos, existen diversos métodos de operación a nivel práctico, no obstante uno de los mayormente usados es el algoritmo de seguimiento del punto de máxima potencia (MPPT). Las características de salida de las celdas fotovoltaicas usualmente no son lineales y se ven afectadas por la radiación y la temperatura ambiente. En pocas palabras, la presencia de factores ambientales como la sombra, nubosidad y algunos otros pueden afectar los picos de entrega de los elementos. Es por esta razón que, se usan los métodos MPPT para asegurar una eficiencia adecuada, según (Mao et al., 2020).

Dentro de los algoritmos MPPT, se encuentran los algoritmos RTTP, que se denominan de seguimiento del punto de referencia, como se puede observar en (Cabrera-Tobar et al., 2019). Su uso es frecuente cuando nos encontramos con condiciones de generación y consumo energético desequilibrados. El RPPT es un algoritmo MPPT modificado, en el que el control funciona cerca de la referencia de potencia fotovoltaica que para este estudio la denominaremos P_{pv} . Entonces la ecuación de salida del sistema fotovoltaico queda definida por la Ecuación 17.

$$P_{pv}(k) = P_{pv,o}(k) - P_{CUR}(k) \quad (17)$$

Donde $P_{pv,o}$ es la potencia del sistema fotovoltaico que se ha calculado usando modelos descritos en (Ahmed et al., 2022; Li et al., 2020). Este modelo se basa en el uso de la irradiancia y temperatura, que se muestran en las Ecuaciones 18 y 19. Mientras tanto, P_{CUR} es la restricción de potencia fotovoltaica derivada del desequilibrio ya mencionado.

$$P_{pv,o}(k) = P_{STC} - \frac{GHI(k)}{G_{STC}} \{1 + \gamma [T_c(k) - T_{c,STC}]\} \quad (18)$$

$$T_c(k) = T_a(k) + \frac{GHI(k)}{800} (NOCT - 20) \quad (19)$$

La Ecuación 20 será la resultante y es la siguiente.

$$P_{pv,o}(k) = P_{STC} - \frac{GHI(k)}{G_{STC}} \left\{ 1 + \gamma \left[T_a(k) + \frac{GHI(k)}{800} (NOCT - 20) - T_{c,STC} \right] \right\} \quad (20)$$

En donde, P_{STC} es la potencia fotovoltaica en condiciones estándar, GHI es la irradiancia horizontal global, G_{STC} es la irradiancia en las condiciones de pruebas estándar, γ es el coeficiente de temperatura de la potencia.

$T_{c,STC}$ es la temperatura de la célula en las condiciones de prueba estandar (STC), T_a es la temperatura ambiente en que se colocará en grados centígrados (°C), y finalmente $NOCT$ es la temperatura nominal de funcionamiento de la celda fotovoltaica.

2.5 Modelo del sistema de generación eólica

El modelo del sistema de generación eólica se fundamenta en lo descrito por De Battista et al. (2006), quienes explican que las propiedades del viento afectan la potencia de salida del aerogenerador, como se formula en la Ecuación 21:

$$P_m = C_p(\lambda, \beta) \frac{\rho A}{2} v_{wind}^3 \quad (21)$$

donde la potencia mecánica de salida está representada por P_m , el coeficiente de rendimiento de la turbina como C_p , mientras que β es el ángulo de paso de la pala, A el área de barrido de la turbina, ρ la densidad del aire, la velocidad del aire se expresa como λ y v_{wind} como la velocidad del viento.

El modelo del coeficiente de rendimiento $C_p(\lambda, \beta)$ empleado en este estudio fue adoptado de la investigación de Lubosny (2003), y se define mediante la Ecuación 22:

$$C_p(\lambda, \beta) = c_1 \left(\frac{c_2}{\lambda_i} - c_3 \beta - c_4 \right) e^{-c_5 / \lambda_i} + c_6 \lambda \quad (22)$$

Donde las constantes desde c_1 hasta c_6 son parámetros que dependen del rotor del aerogenerador y del diseño que tengan las palas, mientras que λ_i es un parámetro que se representa en la Ecuación 23:

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^3 + 1} \quad (23)$$

Por tanto, la Ecuación 24 se puede establecer y simplificar para valores de A y de ρ , como se muestra a continuación:

$$P_{m-pu} = k_p c_{p-pu} v_{wind-pu}^3 \quad (24)$$

Donde para valores de A y de ρ la potencia nominal por unidad (p.u.) se expresa como P_{m-pu} , la ganancia de potencia es k_p , c_{p-pu} es el valor p.u. del coeficiente de rendimiento c_p ,

mientras que $v_{wind-pu}$ es el valor p.u. de la velocidad del viento base, el cual es el valor medio de la velocidad del viento previsto en (m/s). Este modelo utiliza la velocidad del viento y el generador como entradas; el torque aplicado al eje del generador representa la salida (Natsheh et al., 2011).

El modelo del generador de la turbina eólica, para este efecto, el eje del rotor será accionado por la turbina eólica la cual produce el torque mecánico en relación a los valores establecidos del generador y de la velocidad del viento. Como resultado, la salida del generador se conecta a la SG (Natsheh et al., 2011).

2.6 Modelo de EMPC

En una estrategia EMPC, los objetivos suelen estar relacionados con el coste operativo del sistema, como la minimización de los costes de electricidad, en lugar de limitarse a intentar seguir puntos de referencia. En esta investigación, se consideran los siguientes objetivos operativos en la gestión de redes inteligentes vistas como ejemplos de sistemas basados en flujos generalizados. De hecho, los objetivos operativos similares se han utilizado en la gestión de las redes de agua potable (Nassourou, 2021).

- Económico: para minimizar los costes de producción y transporte.
- Seguridad: garantizar que los recursos de los embalses estén siempre al nivel deseado para hacer frente a las incertidumbres y evitar la escasez.
- Suavidad: hacer funcionar la red de forma continua mediante acciones de control suaves.

Para expresar el modelo matemático del Control Predictivo basado en Modelo Económico (EMPC), se adoptó un enfoque de tiempo discreto, comúnmente utilizado en el diseño de controles MPC, como se detalla en las Ecuaciones 25 y 26:

$$\mathbf{x}(k+1) = \mathbf{Ax}(k) + \mathbf{Bu}(k) \quad (25)$$

$$\mathbf{y}(k) = \mathbf{Cx}(k) + \mathbf{Du}(k) \quad (26)$$

donde \mathbf{A} , \mathbf{B} , \mathbf{C} y \mathbf{D} , se consideran las matrices que representan el estado, $\mathbf{x}(k)$ los vectores que representan los estados y $\mathbf{u}(k)$ como aquellas señales en el control. En la Ecuación 27 se expresa la función de coste, se la denomina J . Además Wang et al. (2017) penalizan las desviaciones de la salida controlada, $\mathbf{y}(k+i|k)$, de su valor de referencia, $\mathbf{r}(k+i|k)$.

$$\begin{aligned} J(k) = \min_{\mathbf{u}(k)} & \sum_{i=1}^{H_p} \| \mathbf{y}(k+i|k) - \mathbf{r}(k+i|k) \|_Q^2 \\ & - \sum_{i=0}^{H_u-1} \| \Delta \mathbf{u}(k+i|k) \|_Q^2 \end{aligned} \quad (27)$$

El horizonte de predicción está determinado por H_p , mientras que el rango de control está determinado por H_u , de modo que $H_p \geq H_u$. Los sistemas de control en muchas ocasiones expresan su objetivo basado en la actualidad de dirigir el

proceso de manera rápida y confiable al punto de operación óptimo.

El EMPC opera en un sistema de una manera variable en el tiempo para optimizar la economía del proceso. De tal manera que la función objetivo se expresa en criterios de evaluación o control en actividades como producción, entrega y costos operativos (Wang, 2018).

Para Wang et al. (2017), el modelo de espacio de estado para la energía se obtiene a partir de las ecuaciones de las partes elementales después de la discretización en el tiempo, según se especifica en la Ecuación 28 y 29:

$$\mathbf{x}(k+1) = \mathbf{Ax}(k) + \mathbf{Bu}(k) + \mathbf{B}_p \mathbf{d}(k) \quad (28)$$

$$\mathbf{Eu}(k) + \mathbf{E}_d \mathbf{d}(k) = 0 \quad (29)$$

donde se considera que $\mathbf{x}(k) \in \mathbb{R}^n$, es el vector de estados para el caso en particular, representa el SOC de la batería SOC_{bat} . $\mathbf{u}(k) \in \mathbb{R}^m$, es el vector de variables de control compuesto por la potencia de carga y descarga de la batería p_{bat} , la potencia entregada por el sistema fotovoltaico P_{pv} y la potencia dada por el aereogenerador P_m , $\mathbf{d}(k) \in \mathbb{R}^p$, es el vector que contiene las perturbaciones medidas en el sistema y que son las demandas de potencia p_v para seguir el perfil de demanda.

El sistema total se caracteriza según lo expresado en la Ecuación 30, 31 y 32, diferenciándose en que la energía de la batería se desglosa en componentes positivos y negativos.

$$x_1(k+1) = SOC_{bat}(k) + \frac{p_{ab}(k)}{e_{maxbat}} - \frac{p_{cb}(k)}{e_{maxbat}} \quad (30)$$

$$x_2(k+1) = E_{pv}(k) + \frac{p_{pv}(k)}{e_{maxpv}} \quad (31)$$

$$x_3(k+1) = E_m(k) + \frac{p_m(k)}{e_{maxm}} \quad (32)$$

En la Ecuación 33, los límites de control se transforman en límites operativos, siendo establecidos mediante cotas.

$$\mathbf{u}_{\min}(k) \leq \mathbf{u}(k) \leq \mathbf{u}_{\max}(k) \quad (33)$$

En la Ecuación 34, se expresan las limitaciones operativas sobre los estados los cuales añaden restricciones.

$$\mathbf{x}_{\min}(k) \leq \mathbf{x}(k) \leq \mathbf{x}_{\max}(k) \quad (34)$$

Para Ma et al. (2012), el caso de la función de coste, es la transformación del objetivo de control en una expresión matemática. Bajo este contexto, la función de coste predictiva mediante sus simulaciones y comparaciones nos permitirá incorporar estos aspectos dentro del cómputo matemático de las salidas de control, y por ende optimizar los estados futuros con un horizonte de predicción. En la Ecuación 35, se especifica la función coste típica utilizada en el control EMPC.

$$J_{eco} = \min \left(\sum_{k=0}^{H_p-1} f_1(k) + \sum_{k=0}^{H_p-1} f_2(k) + \sum_{k=0}^{H_p-1} f_3(k) \right) \quad (35)$$

El coste económico de operación viene dado por la Ecuación 36, según se especifica a continuación:

$$f_1(k) = \mathbf{w}_\alpha \mathbf{u}(k) \quad (36)$$

donde \mathbf{w}_α , se plantea en la función coste como el peso económico asignado.

Así también, es necesario mantener los umbrales de seguridad de los equipos de almacenamiento de energía de acuerdo con la normativa viene dado por la Ecuación 37:

$$f_2(k) = \epsilon(k)^T \mathbf{w}_x \epsilon(k) \quad (37)$$

donde $\epsilon(k)$ representa el valor por el cual se penalizarán las restricciones de aquellos elementos de almacenamiento y \mathbf{w}_x contiene los pesos asociados de las penalizaciones.

En la Ecuación 38, se muestra un funcionamiento suave de las actividades de control.

$$f_3(k) = \Delta u(k)^T \mathbf{w}_u \Delta u(k) \quad (38)$$

donde $\Delta \mathbf{u}(k)$ es el vector que permite variar señales de control, mientras que \mathbf{w}_u se conoce como aquella matriz que permite asociar en función de las acciones de control. El algoritmo de simulación del MPC se muestra en la Tabla 2.

Tabla 2. Algoritmo de simulación con función de coste MPC

```

1: Procedimiento CÁLCULO DE LAS SECUENCIAS DE CONTROL (pbat, ppv, pm)
2: Definir coeficientes w (serán simulados en 1)
3: Definir el perfil de demanda de MCI
4: Obtener la potencia del perfil.
5: Definir la masa total del sistema de almacenamiento malmacenamiento.
6: Definir la masa de los elementos de las fuentes principales mpv, mm.
7: Calcular la masa total
8: Calculo de las potencias del sistema.
9: Calculo de energía.
10: Definir SOCmax, SOCmin, epvmax, emax.
11: for {mbat = 0: 1: malmacenamiento} do
    12: Definir pbatmax, pbatmin, ppvmax, ppvmin, pmmax, pmmin.
    13: Definir SOC0, e0.
    14: Definir SOCN, eN.
    15: Definir k, N.
    16: Definir número de elementos de vector de estado y de control Nu, Nx.
    17: Definir Jc.
    18: Discretizar xd = vector [SOC, Nx].
    19: Discretizar ud = vector [pbat, ppv, pm, Nu].
    20: Inicializar U = zeros (Nx, N + 1).
    21: Inicializar Jc(:, N) = h(xd).
    22: Inicializar Jc = ones (Nx, N).
    23: for {k = N - 1 → 0} do
        24: for {i = 1 → Nx} do
            25: for {j = 1 → Nu} do
                26: Coste local = gd(xd(i), ud(j), k).
                27: Estado futuro = xd(i) + fd(xd(i), ud(j), k).
                28: Coste optimo = interpolar (xd, Jc(:, k + 1), xfut).
                29: Coste total C = Cfut + Ci.
                30: if {C ≤ Jc(i, k)} then
                    31: Jc(i, k) = C.
                    32: U(i, k) = ud(j).
                33: end if
            34: end for
        35: end for
    36: end for
    37: save pbat, ppv, pm, SOC
    38: Calcular ev, erec
    39: save ev, erec
40: end for
41: end procedimiento

```

3. DISCUSIÓN DE LOS RESULTADOS

En este estudio, se lograron determinar los resultados a partir de un perfil de potencia específico para la SG. Se evaluó la potencia suministrada por los componentes del sistema utilizando la función de coste.

3.1 Perfil de demanda de potencia

Para el análisis del sistema, se consideró un perfil de demanda de potencia, de tal manera que permita ver cómo se comporta la SG con las restricciones y el dimensionamiento usado para el controlador MPC. El perfil fue dimensionado considerando una potencia máxima de 140 MW, cantidad que normalmente se consume una ciudad pequeña promedio del país, como es el caso de Esmeraldas. La central térmica de MCI tomada en consideración fue la Central Esmeraldas 2, cuyo DCS Emerson DELTA V es capaz de dar los datos de generación de potencia por minuto de las unidades completas en un archivo xls, el mismo que se trasladó a MATLAB para su realizar el análisis gráfico y uso en las matrices de control. El tiempo del ciclo en el perfil es de 1864 minutos, lo que corresponde a un tiempo aproximado de demanda de energía de aproximadamente 31 horas. El perfil de demanda de potencia para medir el funcionamiento de la SG se muestra en la Figura 3.

3.2 Potencia entregada por el controlador MPC

En J_{eco} , definida en la Ecuación 35, se toman en cuenta la potencia de la batería, la potencia del sistema fotovoltaico y la potencia del sistema eólico, así como las variaciones de las potencias y los estados de SOC. Cada uno de estos términos f_1 , f_2 , y f_3 , debe tener un peso relacionado, que se describen como \mathbf{w}_α , \mathbf{w}_x y \mathbf{w}_u . De esta manera, asumiendo que no hay pérdidas en los convertidores y que los componentes pueden proporcionar la máxima potencia, es posible elegir una u otra función de control mediante el ajuste de pesos. Esto implica que matemáticamente el controlador minimiza el uso de cada fuente según las restricciones planteadas, pero cada una es capaz de aportar energía en los instantes de tiempo necesarios.

Los pesos relativos a \mathbf{w}_α , \mathbf{w}_x y \mathbf{w}_u son 0.5, 0.2 y 0.3, con los que se alcanzarán las metas de potencia definidas, sumando un total de 1. Estos pesos fueron escogidos en primera instancia para ponderar el menor coste de operación de los elementos, luego la suavidad de las acciones de control y el cumplimiento de las restricciones en picos de potencia. Posteriormente, se podrá hacer una frontera de Pareto para determinar el mejor valor de cada peso, en función de una variable en particular escogida.

Por ejemplo, \mathbf{w}_α se define en función de los costos ideales de operación; un coeficiente de 1 indica que operar es muy caro y un coeficiente de 0 indica que operar es muy barato. Para el caso de \mathbf{w}_x se espera que un peso de 1 penalice los picos altos de las fuentes de generación y un peso de 0 permita que los picos sean rápidos en el tiempo. Entonces, un peso de 1 permite la operación suave de los elementos pues no admite que la potencia varíe en forma brusca ante la demanda y por ende protege la vida útil de los elementos. De igual manera, sucede con \mathbf{w}_u .

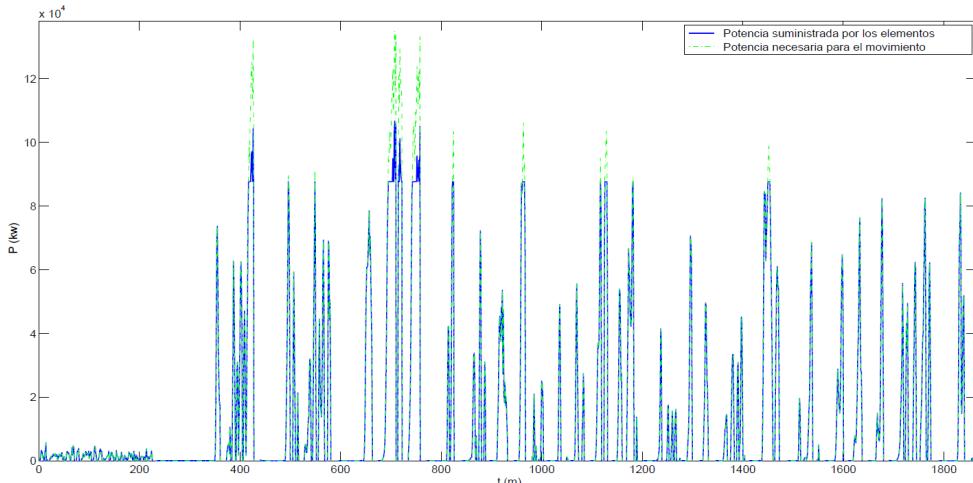


Figura 3. Perfil de demanda de potencia

La función J_{eco} , recopila los modelos de estado de salud de la batería y el objetivo económico de ahorro, además de permitir analizar el comportamiento de cada una de las fuentes de generación en respuesta a la demanda del perfil de potencia de la Figura 3. La función de coste estima la energía fotovoltaica, el SOC de la batería y la energía eólica. Como resultado de aquello, fue posible analizar la dinámica de cada componente del sistema en respuesta a la demanda. Con los pesos escogidos, las fuentes de energía eólica y solar suministran menos picos de energía, lo que hace que la batería almacene una mayor cantidad de energía, para después aportarla a la demanda.

La potencia máxima de la fuente eólica nominal es de 80 MW. La potencia máxima de la energía solar es de 60 MW y la de la batería se puede visualizar en la Tabla 1.

3.3 Análisis del primer caso de simulación

Debemos recordar que los pesos utilizados son \mathbf{w}_α , \mathbf{w}_x y \mathbf{w}_u con 0.5, 0.2 y 0.3. Lo primero que se procede a comprobar es que cuando se asume que la potencia de la batería es igual a 0, las dos fuentes restantes, la eólica y la solar no son capaces de suministrar toda la energía que pide el perfil de potencia. Entonces, la Figura 4 muestra la potencia suministrada por los elementos eólico y solar con la función J_{eco} , cuando se coloca que la potencia máxima de la batería es cero.

En verde, se grafica la potencia necesaria, mientras en azul la potencia resultante de la sumatoria de las fuentes. Se puede notar claramente que en los picos más altos de tiempo, no se puede cumplir la demanda de potencia. Solamente un 86% de la energía necesaria se aporta a la demanda. Del análisis de la función J_{eco} , se podría deducir que si no se penalizaría el control suave y los picos de potencia, estas fuentes podrían cumplir la demanda aunque no operasen en sus regiones de máxima eficiencia, pero afectaría a su vida útil.

Se ha considerado un horizonte de predicción de 60 segundos para esta función de coste. El aumentar el horizonte de predicción hace que el controlador se vuelva más lento y mientras más se acerque al horizonte total, el controlador pierde las bondades de enviar una respuesta a los sistemas

físicos en los tiempos de actuación necesarios. El tiempo de entrega de información del DCS físico tomado es de 1 minuto, por lo que también se pondera al momento de colocar el horizonte de predicción.

3.4 Análisis del segundo caso de simulación

Tomando en consideración que las 2 fuentes principales no son suficientes para cubrir la demanda energética, es necesario insertar la potencia de la batería que ya se ha mostrado en la Tabla 1 de dimensionamiento de la misma en las secciones anteriores.

Para la misma configuración de pesos, la Figura 5 muestra la potencia de la batería y la Figura 6 la suma de la potencia de las 3 fuentes en relación a la demanda. Es importante indicar que la batería aporta energía pero también es capaz de guardar la misma para luego poder aportarla.

En la Figura 6, se puede visualizar que las líneas azules y rojas están casi sobre puestas. Esto implica que todo el perfil de demanda se cumple en un 99,96%. Con relación al primer caso de simulación, podemos observar que la batería nos permite mediante la función de coste propuesta llegar a cumplir la demanda.

En la Figura 7, se muestra una porción del intervalo total, entre 800 y 900 minutos, y se puede observar que se cumple el perfil de manera adecuada.

En los dos escenarios, se obtiene que la fuente eólica aporta un 25% más que la fuente solar, y entre ambas logran un aproximado de 123 MW. Pero en el segundo escenario, la cantidad de energía aportada por la batería es de cerca del 13,70 % y en términos de recuperación de energía es similar.

En el presente trabajo, no se hace un estudio de Pareto u otras técnicas para determinar el pesaje ideal, no obstante, se comprueba la validez del controlador multifunción MPC para cumplir el perfil de demanda con las fuentes usadas. De manera ilustrativa se muestra la comparación de dos escenarios de SOC.

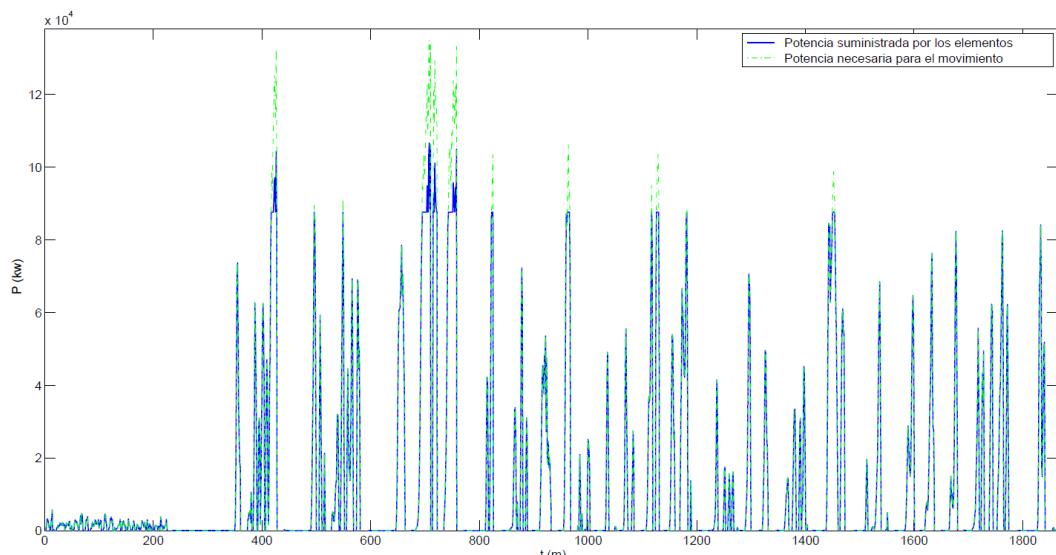


Figura 4. Comparación de la potencia suministrada por la fuente eólica y solar para J_{eco}

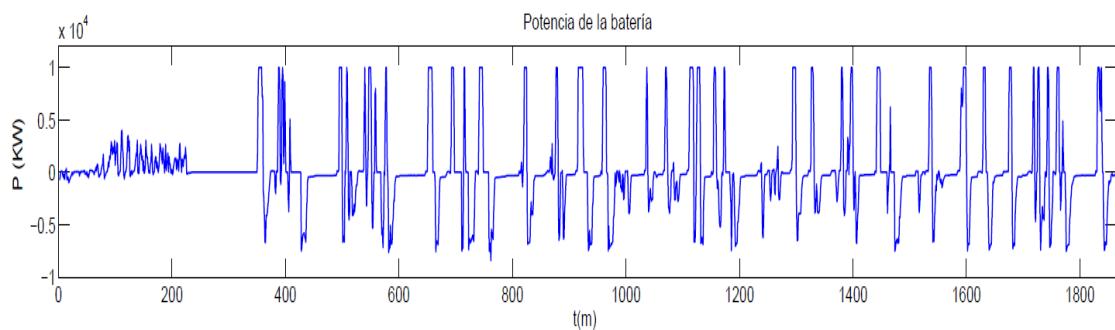


Figura 5. Potencia aportada por la batería a la demanda de energía planteada

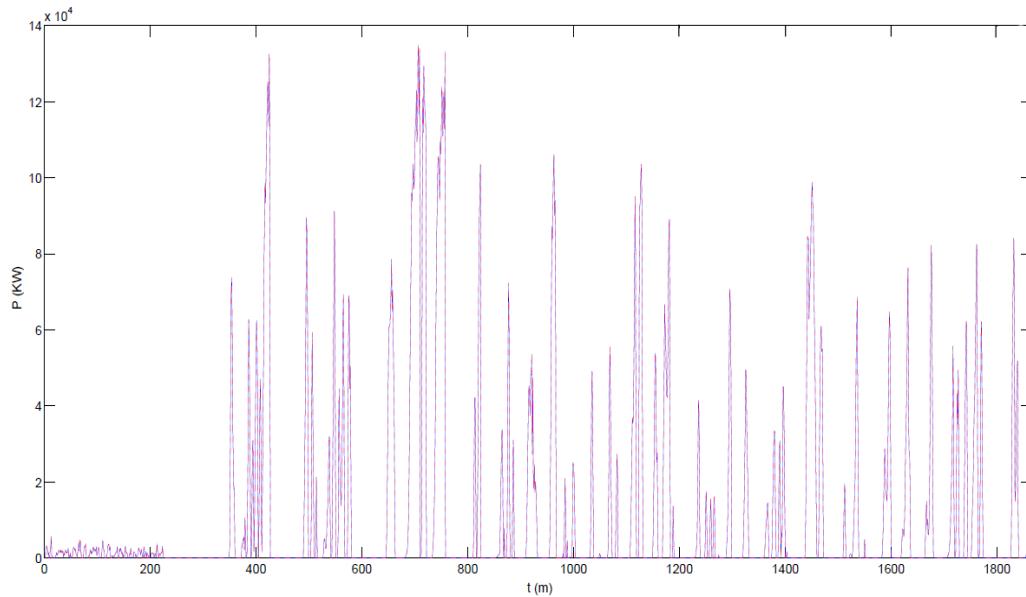


Figura 6. Comparación de la potencia suministrada todas las fuentes de generación versus la demanda

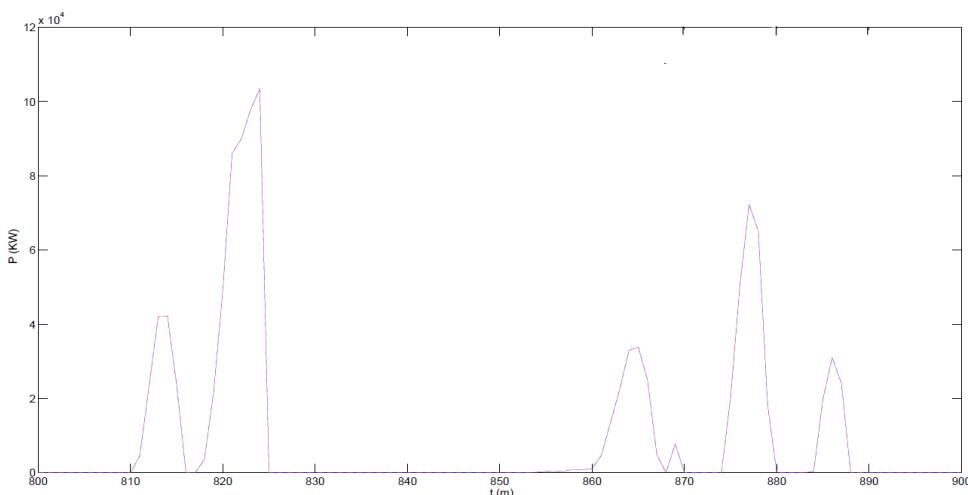


Figura 7. Comparación de la potencia suministrada todas las fuentes de generación versus la demanda

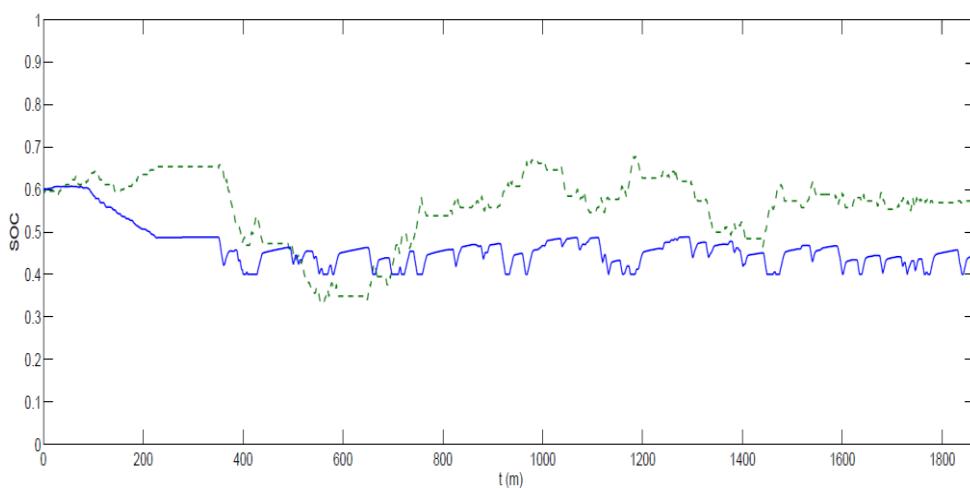


Figura 8. Comparación de distintos SOCS para valores de pesos distintos

Se identifica que el comportamiento del SOC, dentro del controlador MPC, puede ser controlado por el peso de las funciones, siempre y cuando no excedan los límites de SOC permitidos. Aunque no es parte del alcance de este estudio, solamente para ilustrar que el SOC de la batería cambia dependiendo de la cantidad de energía que se le permite recuperar y entregar mediante la variación de pesos, en la Figura 8 se muestran dos SOCs distintos para diferentes valores de pesos.

En verde, podemos ver un paisaje que permite recuperar más energía y en azul uno que permite recuperar menor energía, por ende el aporte será menor.

4. CONCLUSIONES

La arquitectura de la SG se basa en dos fuentes principales que son la energía solar y eólica, además de una fuente de almacenamiento conformada por una batería, todas conectadas con su respectiva instrumentación a un bus de potencia que se conecta a la carga, mediante los instrumentos adecuados que no son objeto de modelamiento de este estudio. La instrumentación se modela como buses de conexión y se embeben como constantes en el modelo matemático de las fuentes y elementos de almacenamiento.

El controlador MPC con una función de coste basada en funciones individuales que penalizan distintas variables, es adecuado para optimizar la generación y almacenamiento de energía en una SG. La función de coste considera coeficientes distintos para fuentes fotovoltaicas, eólicas y baterías, no obstante, en este estudio se han considerado como pesos iguales en el valor de 1. La variación que este estudio contempla son los pesos asociados a cada función, para optimizar la operación suave y la operación económica de cada una de las fuentes principales y elementos de almacenamiento. Con la configuración de dos pesos distintos, el MPC ha sido capaz de cumplir con la demanda solicitada, permitiendo la absorción y entrega eficiente de energía. Se incluyeron en el controlador restricciones como el SOC de la batería y las potencias de la SG. El perfil de potencia revela un aumento significativo en la contribución de la generación solar y eólica con el uso del controlador MPC, debido a que son las fuentes de mayor capacidad de potencia. La aplicación del MPC, permite variar los costes operativos y por ende con la configuración adecuada de pesos, convirtiéndose en una herramienta útil para reducir los costos asociados a la generación de electricidad.

La herramienta desarrollada a nivel metodológico es de gran relevancia, pues permite incluir distintas fuentes de generación como matrices dentro del espacio de estados.

Únicamente se debe variar la ecuación de control, y la función de coste ajusta los parámetros de las distintas fuentes como restricciones.

Por ejemplo, puede entonces asociarse a distintas herramientas de almacenamiento como supercapacitores, y otras fuentes como las que usan hidrógeno. Se destaca la versatilidad de usar un elemento de almacenamiento con gran densidad energética, para suplir los picos en demandas altas y para dar potencia en regiones de poca eficiencia de los demás elementos. El error entre la generación y la demanda es de 0.03 %, y se debe a que no han sido ajustados los coeficientes de las fuentes como tal.

El objetivo del estudio se ha cumplido a cabalidad, y es cumplir el perfil en la demanda pico y en demandas inferiores, con el horizonte de predicción indicado. La demanda se genera en base al consumo real con datos del DCS de la central térmica mencionada, lo que hace a la herramienta útil, pues se ha testeado sobre datos reales de generación. La recuperación de energía es de cerca del 13 % y puede aumentar en función de la modificación de los coeficientes de la batería y de variar los límites del SOC, no obstante, no es el objetivo de este estudio.

Es importante indicar que la herramienta permite variar costes operacionales, y por ende colocar distintos máximos de potencia y energía para los elementos, lo que nos permitirá inclusive obtener una proyección económica de vida útil y de gasto de dinero en función de la generación requerida.

REFERENCIAS

- Abril, S. O., León, J. A. P., & Mendoza, J. O. G. (2021). STUDY OF THE BENEFIT OF SOLAR ENERGY THROUGH THE MANAGEMENT OF PHOTOVOLTAIC SYSTEMS IN COLOMBIA. *International Journal of Energy Economics and Policy*, 11(2), 96-103. <https://doi.org/10.32479/ijep.10706>
- Ahmad, A., & Khan, J. Y. (2020). Real-Time Load Scheduling, Energy Storage Control and Comfort Management for Grid-Connected Solar Integrated Smart Buildings. *Applied Energy*, 259, 114208. <https://doi.org/10.1016/j.apenergy.2019.114208>
- Ahmed, M., Harbi, I., Kennel, R., Heldwein, M. L., Rodríguez, J., & Abdelrahem, M. (2022). Performance Evaluation of PV Model-Based Maximum Power Point Tracking Techniques. *Electronics*, 11(16). <https://doi.org/10.3390/electronics11162563>
- Arce, A., Real, A., & Bordons, C. (2014). Combined environmental and economic dispatch of smart grids using distributed model predictive control. *International Journal of Electrical Power & Energy Systems*, 54, 65-76. <https://doi.org/10.1016/j.ijepes.2013.06.035>
- Basit, A., Sarosh, A., Ahmed, O. A. A., Shuaib, H., & Khan, A. R. (2024). Performance Characterization of EEEC (Eolic Energy Unit) for Horizontal Axis Wind Turbine. En A. A. Khan, M. S. Hossain, M. Fotouhi, A. Steuwer, A. Khan, & D. F. Kurtulus (Eds.), *Proceedings of the First International Conference on Aeronautical Sciences, Engineering and Technology* (pp. 302-310). Springer Nature Singapore. https://doi.org/10.1007/978-981-99-7775-8_32
- Cabrera-Tobar, A., Bullich-Massagué, E., Aragüés-Peñaiba, M., & Gomis-Bellmunt, O. (2019). Active and Reactive Power Control of a PV Generator for Grid Code Compliance. *Energies*, 12(20). <https://doi.org/10.3390/en12203872>
- Carignano, M., Adorno, R., van Dijk, N., Nieberding, N., Nigro, N., & Orbaiz, P. (2016, junio 19). *Assessment of Energy Management Strategies for a Hybrid Electric Bus*.
- Carignano, M., Roda, V., Costa-Castelló, R., Valiño, L., Lozano, A., & Barreras, F. (2019). Assessment of Energy Management in a Fuel Cell/Battery Hybrid Vehicle. *IEEE Access*, 7, 16110-16122. <https://doi.org/10.1109/ACCESS.2018.2889738>
- De Battista, H., Mantz, R. J., & Garelli, F. (2006). Power conditioning for a wind-hydrogen energy system. *Journal of Power Sources*, 155(2), 478-486. <https://doi.org/10.1016/j.jpowsour.2005.05.005>
- Del Real, A. J., Arce, A., & Bordons, C. (2014). Combined environmental and economic dispatch of smart grids using distributed model predictive control. *International Journal of Electrical Power & Energy Systems*, 54, 65-76. <https://doi.org/10.1016/j.ijepes.2013.06.035>
- Freire, V. A., De Arruda, L. V. R., Bordons, C., & Márquez, J. J. (2020). Optimal Demand Response Management of a Residential Microgrid Using Model Predictive Control. *IEEE Access*, 8, 228264-228276. IEEE Access. <https://doi.org/10.1109/ACCESS.2020.3045459>
- Halvgaard, R., Vandenberghe, L., Poulsen, N. K., Madsen, H., & Jørgensen, J. B. (2016). Distributed Model Predictive Control for Smart Energy Systems. *IEEE Transactions on Smart Grid*, 7(3), 1675-1682. <https://doi.org/10.1109/TSG.2016.2526077>
- Hu, J., Shan, Y., Guerrero, J. M., Ioinovici, A., Chan, K. W., & Rodriguez, J. (2021). Model predictive control of microgrids – An overview. *Renewable and Sustainable Energy Reviews*, 136, 110422. <https://doi.org/10.1016/j.rser.2020.110422>
- Jia, Y., & Sun, C. (2017). Distributed MPC with application to AGC of power system with wind-photovoltaic hybrid generation. *2017 36th Chinese Control Conference (CCC)*, 4676-4681. <https://doi.org/10.23919/ChiCC.2017.8028091>
- Johnson, V. H. (2002). Battery performance models in ADVISOR. *Journal of Power Sources*, 110(2), 321-329. [https://doi.org/10.1016/S0378-7753\(02\)00194-5](https://doi.org/10.1016/S0378-7753(02)00194-5)
- Kim, D., Wang, Z., Brugger, J., Blum, D., Wetter, M., Hong, T., & Piette, M. A. (2022). Site demonstration and performance evaluation of MPC for a large

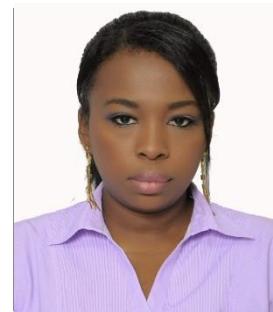
- chiller plant with TES for renewable energy integration and grid decarbonization. *Applied Energy*, 321, 119343. <https://doi.org/10.1016/j.apenergy.2022.119343>
- Li, C., Spataru, S. V., Zhang, K., Yang, Y., & Wei, H. (2020). A Multi-State Dynamic Thermal Model for Accurate Photovoltaic Cell Temperature Estimation. *IEEE Journal of Photovoltaics*, 10(5), 1465-1473. <https://doi.org/10.1109/JPHOTOV.2020.2987401>
- Lubosny, Z. (2003). *Wind Turbine Operation in Electric Power Systems: Advanced Modeling*. Springer. <https://doi.org/10.1007/978-3-662-10944-1>
- Ma, A., Wu, T., & Liu, H. (2019). A Model Predictive Control for Maximum Power Point Tracking of Wind Energy Conversion Systems. *Proceedings of the 2019 The 2nd International Conference on Robotics, Control and Automation Engineering*, 118-122. <https://doi.org/10.1145/3372047.3372081>
- Ma, J., Qin, J., Salsbury, T., & Xu, P. (2012). Demand reduction in building energy systems based on economic model predictive control. *Chemical Engineering Science*, 67, 92-100. <https://doi.org/10.1016/j.ces.2011.07.052>
- Mao, M., Cui, L., Zhang, Q., Guo, K., Zhou, L., & Huang, H. (2020). Classification and summarization of solar photovoltaic MPPT techniques: A review based on traditional and intelligent control strategies. *Energy Reports*, 6, 1312-1327. <https://doi.org/10.1016/j.egyr.2020.05.013>
- Montoya, Y., Ramírez, E., Pérez, T., Rujano, L., & Pérez, N. (2015). Estado del arte de smart grig: Parte I. *Revista Ingeniería al Día*, 2, 21.
- Kirn Kumar N., Indra Gandhi, V., Ravi, L., Vijayakumar, V. & Subramaniyaswamy, V. (2020). Improving security for wind energy systems in smart grid applications using digital protection technique. *Sustainable Cities and Society*, 60, 102265. <https://doi.org/10.1016/j.scs.2020.102265>
- Nassourou, M. (2021). *Robust Economic Model Predictive Control of Smart Grids* [Tesis doctoral, Universitat Politècnica de Catalunya]. <https://futur.upc.edu/32056680>
- Nassourou, M., Blesa, J., & Puig, V. (2018). Optimal energy dispatch in a smart micro-grid system using economic model predictive control. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 234, 095965181878637. <https://doi.org/10.1177/0959651818786376>
- Natsheh, E. M., Albarbar, A., & Yazdani, J. (2011). Modeling and control for smart grid integration of solar/wind energy conversion system. *2011 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies*, 1-8. <https://doi.org/10.1109/ISGTEurope.2011.6162643>
- Oshnoei, A., Kheradmandi, M., Khezri, R., & Mahmoudi, A. (2021). Robust Model Predictive Control of Gate-Controlled Series Capacitor for LFC of Power Systems. *IEEE Transactions on Industrial Informatics*, 17(7), 4766-4776. IEEE Transactions on Industrial Informatics. <https://doi.org/10.1109/TII.2020.3016992>
- Phang, J. C. H., Chan, D. S. H., & Phillips, J. R. (1984). Accurate analytical method for the extraction of solar cell model parameters. *Electronics Letters*, 20(10), 406-408. <https://doi.org/10.1049/el:19840281>
- Poursmaeil, B., Hosseinpour Najmi, P., & Najafi Ravadanegh, S. (2021). Interconnected-energy hubs robust energy management and scheduling in the presence of electric vehicles considering uncertainties. *Journal of Cleaner Production*, 316, 128167. <https://doi.org/10.1016/j.jclepro.2021.128167>
- Ravat, A. K., Dhawan, A., & Tiwari, M. (2021). LMI and YALMIP: Modeling and Optimization Toolbox in MATLAB. En D. Harvey, H. Kar, S. Verma, & V. Bhadauria (Eds.), *Advances in VLSI, Communication, and Signal Processing* (Vol. 683, pp. 507-515). Springer Singapore. https://doi.org/10.1007/978-981-15-6840-4_41
- Segovia, P., Rajaoarisoa, L., Nejjari, F., Duviella, E., & Puig, V. (2019). Model predictive control and moving horizon estimation for water level regulation in inland waterways. *Journal of Process Control*, 76, 1-14. <https://doi.org/10.1016/j.jprocont.2018.12.017>
- Shi, Y., Tuan, H. D., Savkin, A. V., Duong, T. Q., & Poor, H. V. (2019). Model Predictive Control for Smart Grids With Multiple Electric-Vehicle Charging Stations. *IEEE Transactions on Smart Grid*, 10(2), 2127-2136. <https://doi.org/10.1109/TSG.2017.2789333>
- Shi, Y., Tuan, H. D., Savkin, A. V., Lin, C.-T., Zhu, J. G., & Poor, H. V. (2021). Distributed model predictive control for joint coordination of demand response and optimal power flow with renewables in smart grid. *Applied Energy*, 290, 116701. <https://doi.org/10.1016/j.apenergy.2021.116701>
- Sun, D., Jamshidnejad, A., & De Schutter, B. (2023). Optimal Sub-References for Setpoint Tracking: A Multi-level MPC Approach. *22nd IFAC World Congress*, 56(2), 9411-9416. <https://doi.org/10.1016/j.ifacol.2023.10.233>
- Vardhan, B. V. S., Khedkar, M., & Srivastava, I. (2022). Effective energy management and cost effective day ahead scheduling for distribution system with dynamic market participants. *Sustainable Energy, Grids and Networks*, 31, 100706. <https://doi.org/10.1016/j.segan.2022.100706>
- Velasquez, M. A., Quijano, N., Cadena, A. I., & Shahidehpour, M. (2021). Distributed stochastic economic dispatch via model predictive control and data-driven scenario generation. *International Journal of Electrical Power & Energy Systems*, 129, 106796. <https://doi.org/10.1016/j.ijepes.2021.106796>
- Wang, Y. (2018). Advances in state estimation, diagnosis and control of complex systems [Ph.D. Thesis, Universitat Politècnica de Catalunya]. En *TDX (Tesis Doctorals en Xarxa)*. <https://www.tdx.cat/handle/10803/669680>

Wang, Y., Puig, V., & Cembrano, G. (2017). Non-linear economic model predictive control of water distribution networks. *Journal of Process Control*, 56, 23-34.
<https://doi.org/10.1016/j.jprocont.2017.05.004>

Wenzhong Gao. (2005). Performance comparison of a fuel cell-battery hybrid powertrain and a fuel cell-ultracapacitor hybrid powertrain. *IEEE Transactions on Vehicular Technology*, 54(3), 846-855.
<https://doi.org/10.1109/TVT.2005.847229>

Yelisetti, S., Kumar, R., Gupta, V., Saxena, A., & Lamba, R. (2020). Modelling and Analysis of Home Energy Management System Using Intelligent Algorithms. *2020 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)*, 1-6.
<https://doi.org/10.1109/ICPECTS49113.2020.9337014>

Robótica y Visión Avanzada por Computador en la Universidad Politécnica de Catalunya (2019).



Nakira, Valencia, graduada de Ingeniería en Electrónica y Telecomunicaciones por la Escuela Superior Politécnica del Litoral. Máster Universitario en Ingeniería Matemáticas y Computación por la Universidad Internacional de La Rioja. Doctorante en Innovación Didáctica y formación del Profesorado, mención Didáctica de las Matemáticas en la Universidad de Jaen – España. Docente en la Universidad Técnica Luis Vargas Torres de Esmeraldas.



Raúl, Ulloa, graduado de Ingeniería Eléctrica por la Escuela Politécnica Nacional, Magíster en Ingeniería Eléctrica en Distribución por la Escuela Politécnica Nacional, Magíster en Administración de Empresas con Especialidad en Gerencia de Proyectos por la Universidad Prat de Chile.



Jorge, Checa, graduado en Ingeniería Eléctrica por la Universidad Técnica Estatal de Quevedo (UTEQ) en 2016 y Máster en Electricidad Mención Energías Renovables y Eficiencia Energética en la Pontificia Universidad Católica del Ecuador (2024). Actualmente investigador, coordinador de proyectos y actividades de vinculación con la sociedad y docente de la carrera de Tecnología Superior en Electricidad en el Instituto Superior Tecnológico Ciudad de Valencia. Sus áreas de interés en investigación son sistemas de gestión de energía, sistemas de control modernos.



Ana, Cabrera, graduada de Ingeniería en Electricidad con especialización en Electrónica y Automatización Industrial (2010)Por la Escuela Politécnica Del Litoral y Magíster en Automatización y Control por la Escuela Politécnica Del Litoral (2020). Docente de la universidad ECOTEC.



José, Sampietro, graduado de Ingeniería en Electrónica, Automatización y Control Por la Universidad de las Fuerzas Armadas del Ecuador y Máster en Automática y Robótica por la Universidad Politécnica de Catalunya, Master en Ingeniería de la Organización Industrial por la Universidad Politécnica de Catalunya. Doctor en Automática,

