

Resolución del problema de optimización bi-objetivo para el despacho de plantas hidroeléctricas en condiciones de bajo caudal de entrada utilizando el algoritmo NSGA II

Resolution of the bi-objective optimization problem for the dispatch of hydroelectric plants under conditions of low inflow using the NSGA II algorithm

César A. Yajure-Ramírez¹ <https://orcid.org/0000-0002-3813-7606>

¹Universidad Central de Venezuela, Caracas, Venezuela
cyajure@gmail.com



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Enviado: 2024/03/06

Aceptado: 2024/06/02

Publicado: 2024/06/30

Resumen

Entre las consecuencias del cambio climático se encuentran el aumento de la temperatura y cambios en los patrones de caída de lluvia que traen períodos de sequía más largos. Esto crea limitaciones en la administración de los embalses de las plantas hidroeléctricas, restringiendo en algunos casos la cantidad de energía eléctrica generada. El objetivo de esta investigación consiste en resolver el problema de optimización multiobjetivo que busca minimizar la producción de energía eléctrica de plantas hidroeléctricas con bajo caudal de entrada y, a la vez, minimizar el racionamiento eléctrico debido a esa baja producción. Al ser objetivos contrapuestos entre sí, se hizo necesario aplicar las metodologías de resolución de problemas de optimización multiobjetivo entre las que se encuentran los algoritmos genéticos. El modelo matemático se construyó considerando las condiciones operativas de los embalses de las plantas hidroeléctricas bajo estudio, tomando en cuenta sus cotas de operación mínima, las cuales son incluidas en las restricciones del modelo. Se utilizó el algoritmo genético de clasificación no dominado II para obtener el frente de Pareto, el cual resultó compuesto por un total de 78 soluciones no dominadas, las que fueron útiles para administrar los embalses considerados, a la hora de máxima demanda. En definitiva, se recomienda utilizar otros algoritmos de optimización multiobjetivo para efectos de comparación, seleccionando los indicadores idóneos para evaluar el desempeño de cada algoritmo empleado, además de incorporar restricciones de costos monetarios y ambientales al modelo.

Sumario: Introducción, Materiales y Métodos, Resultados y Discusión y Conclusiones.

Como citar: Yajure-Ramírez, C. (2024). Resolución del problema de optimización bi-objetivo para el despacho de plantas hidroeléctricas en condiciones de bajo caudal de entrada utilizando el algoritmo NSGA II. *Revista Tecnológica - Espol*, 36(1), 32-43.
<https://rte.espol.edu.ec/index.php/tecnologica/article/view/1146>

Palabras clave: Cambio climático, frente de Pareto, generación eléctrica, NSGA, racionamiento eléctrico.

Abstract

Among the consequences of climate change are increased temperatures and changes in rainfall patterns that bring longer periods of drought. This creates limitations in the administration of hydroelectric plant reservoirs, restricting, in some cases, the amount of electrical energy generated. The objective of this research is to solve the multi-objective optimization problem that seeks to minimize the production of electrical energy from hydroelectric plants with low inflow and, at the same time, minimize electrical rationing due to this low production. As these objectives conflict with each other, it is necessary to apply multi-objective optimization problem-solving methodologies, among which are genetic algorithms. The mathematical model is built considering the operating conditions of the reservoirs of the hydroelectric plants under study, including their minimum operating levels, which are included in the model restrictions. The non-dominated genetic classification algorithm II is used to obtain the Pareto front, which is composed of a total of 78 non-dominated solutions that are useful to manage the considered reservoirs at the time of maximum demand. It is recommended to use other multi-objective optimization algorithms for comparison purposes, selecting the ideal indicators to evaluate the performance of each algorithm used, in addition to incorporating monetary and environmental cost restrictions into the model.

Keywords: Climate change, Pareto front, electricity generation, NSGA, electricity rationing.

Introducción

Las plantas de energía hidroeléctrica se basan en la conversión de la energía potencial asociada a la diferencia de nivel del agua almacenada en los embalses construidos para tal fin. La energía hidroeléctrica “se genera gracias al flujo de agua y utilizando tecnología mecánica tal como las turbinas para hacer la conversión de la energía” (Ahmad et al., 2019). Esta energía asociada al agua almacenada o en movimiento forma parte de las conocidas energías renovables. Para el año 2022, el 30% del total de generación eléctrica a nivel mundial fue suministrada por las fuentes renovables, siendo un poco más de la mitad de la generación de electricidad del tipo hidroeléctrica (REN21, 2023). Asimismo, en Latinoamérica el 45% del total de generación de electricidad proviene de plantas hidroeléctricas (Agencia Internacional de Energía, 2021).

Ahora bien, el cambio climático puede generar cambios en la temperatura ambiental y en los patrones de caída de las lluvias, afectando la disponibilidad de agua para las plantas hidroeléctricas (Okoye et al., 2023). Asimismo, algunos fenómenos climáticos podrían generar períodos de sequía en algunas partes del planeta que impactarían negativamente, entre otras cosas, los niveles de los embalses asociados a las plantas hidroeléctricas. En países con una matriz energética tal que más del 50% está compuesta de energía hidroeléctrica, el impacto de estos fenómenos climáticos podría ocasionar un aumento en el racionamiento de la energía a buena parte de la población. Por ejemplo, en presencia del fenómeno de “El Niño” se intensifica la sequía en algunos países latinoamericanos. Según López (2024), “El Niño” es el principal responsable de la sequía que experimenta Venezuela desde julio del año 2023 y, de acuerdo con el Centro de Predicción Climática de los Estados Unidos (National Oceanic and Atmospheric Administration, 2024), se espera que los efectos de este fenómeno climático estén presentes hasta al menos el mes de abril del año 2024.

Por lo anterior, en presencia de condiciones de un atípico bajo caudal de entrada a los embalses de las plantas hidroeléctricas, se hace necesario administrar su uso para evitar llegar a los niveles mínimos de operación. Esto podría disminuir la energía eléctrica generada y aumentar así el racionamiento eléctrico, en caso de no existir otros tipos de plantas de generación que compensen tal disminución. Esta situación acarrea un problema de optimización de dos objetivos contrapuestos en el que se busca disminuir la energía eléctrica generada por las plantas para no alcanzar a los niveles mínimos de operación de los embalses, pero también reducir el racionamiento eléctrico para así minimizar el impacto en la población. Para resolver este tipo de problemas, se puede aplicar alguna de las técnicas de optimización multiobjetivo disponibles. En ese sentido, la finalidad de esta investigación es aplicar algoritmos evolutivos multiobjetivo para establecer el despacho de plantas hidroeléctricas que tienen condiciones de bajo caudal de entrada a los embalses. Para ello, se utiliza el algoritmo genético de clasificación de soluciones no dominadas de segunda generación (NSGA II), buscando minimizar simultáneamente la generación eléctrica de dos plantas hidroeléctricas y el racionamiento eléctrico de la región que es abastecida por dichas plantas.

Se hizo una revisión bibliográfica de las investigaciones relacionadas con este tema, y no se encontró alguna en la que se busque reducir simultáneamente la generación de las plantas hidroeléctricas y el racionamiento eléctrico. Por ejemplo, Huang et al. (2023) utilizan el algoritmo NSGA II para optimizar dos funciones objetivo, la generación de una planta hidroeléctrica ubicada en China, la cual sirve para regular el pico de demanda, y la disponibilidad de navegación del canal marítimo que se alimenta del caudal proveniente de la planta. Entre las restricciones consideradas se encuentran las cotas seguras para el embalse, el caudal de salida de la planta, y los límites de la potencia eléctrica de la planta. Los resultados obtenidos permiten programar tanto la operación de la planta como el uso del canal de navegación.

Asimismo, Jena et al. (2022) hacen uso del algoritmo NSGA II para resolver un problema de optimización de dos objetivos que le permita programar la operación de plantas hidráulicas, plantas térmicas, plantas solares fotovoltaicas, y plantas eólicas, minimizando los costos de operación y las emisiones contaminantes del sistema. Los resultados numéricos son comparados con los del algoritmo SPEA 2, obteniendo que el uso del NSGA II genera mayor disminución del costo y de las emisiones.

Por otra parte, Hojjati et al. (2018) aplican y comparan los algoritmos NSGA II y MOPSO (*multi-objective particle swarm optimization*) para mejorar la operación de embalses de agua, maximizando los ingresos provenientes de la generación de potencia y el volumen almacenado de agua. Se consideran restricciones asociadas al balance de agua en el embalse, a los límites de liberación del caudal de agua, y al caudal mínimo “aguas abajo” para protección del medio ambiente. Los investigadores concluyen que el algoritmo NSGA II tiene un mejor desempeño con mejoras del 22% y el 3% en los ingresos y el volumen, respectivamente, al compararlo con los resultados del MOPSO.

Además, Sun et al. (2018) utilizan el algoritmo evolutivo multiobjetivo basado en descomposición con ajuste de vector de peso adaptativo (MOEA/D-AWA) para optimizar la operación de embalses de agua. Como funciones objetivo tienen la maximización de la potencia generada por la planta hidroeléctrica, y la maximización del desvío de caudal de agua de la salida del embalse. Consideran restricciones de balance de agua en el reservorio, generación de potencia eléctrica, y el caudal de diseño de la estación de bombeo. El estudio determina que el modelo propuesto es efectivo para resolver el problema de optimización de operación de embalses de agua.

Por otro lado, Zhou et al. (2003) hacen uso del algoritmo de optimización de clasificación de soluciones no dominadas (NSBWO) para mejorar la operación de plantas hidroeléctricas considerando los tiempos de llegada de las naves al embalse. Las restricciones incluyen los límites de las cotas de los embalses, del flujo de descarga de la planta, de la potencia de las unidades, tasa de variación de los niveles de agua, entre otras. Como resultado obtuvieron un plan de operación diario óptimo para la planta hidroeléctrica.

De igual forma, Wei et al. (2022) plantean un modelo de optimización multiobjetivo para aumentar la generación de energía que produce una planta hidroeléctrica y a la vez maximizar el desvío de agua del embalse del sistema. Aplican el algoritmo NSGA II-SEABODE, el que combina la optimización multiobjetivo y la toma de decisiones multiatributo. Las restricciones consideradas incluyen balance de agua, límites de cotas del embalse, límites en la potencia de salida, límites en el flujo de bombeo y límites en el caudal ecológico. Los resultados muestran que la metodología puede promover la utilización eficiente de los recursos hídricos.

Adicionalmente, Li & Qiu (2015) plantean el uso de un modelo de optimización multiobjetivo basado en el algoritmo NSGA II para maximizar la generación anual de energía eléctrica mientras se maximiza la potencia firme de la planta hidroeléctrica. Las restricciones consideradas en el modelo están relacionadas con los límites de las cotas del embalse, los límites de la descarga de agua del embalse, balance de agua, entre otras. Concluyen que la metodología propuesta, además de ser efectiva, muestra una relación cuantitativa entre la generación de energía y la potencia firme.

Finalmente, Marcelino et al. (2021) proponen un modelo de optimización multiobjetivo para maximizar la potencia generada de una planta hidroeléctrica y simultáneamente maximizar el volumen total de agua en un conjunto de embalses. Utilizan el algoritmo evolutivo multiobjetivo de hibridación de enjambres (MESH), y comparan sus resultados con los de los algoritmos NSGA II, NSGA III, SPEA II, y MOEA/D. Sus hallazgos indican que el MESH presenta un mejor desempeño, en comparación con el resto de los algoritmos, en términos de eficiencia y exactitud.

El resto del artículo se distribuye de la siguiente manera. En la sección 2 se presenta la metodología utilizada, luego en la sección 3 se discuten los resultados obtenidos; seguidamente, se presentan las conclusiones que se derivan de la investigación y, finalmente, se tienen las referencias bibliográficas utilizadas.

Materiales y Métodos

En primer lugar, se definieron las funciones objetivo que deben ser optimizadas, tomando en cuenta las condiciones de los embalses, debidas al aumento de la demanda eléctrica, y al fenómeno “El Niño” que genera sequía y, por consiguiente, bajo caudal de entrada. La primera función objetivo consistió en minimizar la producción de energía eléctrica en las plantas de generación hidroeléctrica bajo estudio, correspondientes a los embalses 1 y 2, para así disminuir el consumo del agua almacenada, puesto que se espera poco caudal de entrada en el corto y mediano plazo, y la segunda función fue minimizar el racionamiento eléctrico en dicha región. Es evidente que estos dos objetivos son contrapuestos ya que minimizar la producción de la energía eléctrica generada por las plantas hidroeléctricas implica un posible aumento en el racionamiento eléctrico si no se dispone de otras fuentes de generación que compensen tal disminución. El racionamiento eléctrico vendrá dado como la diferencia entre la demanda máxima en la región bajo estudio y los distintos aportes de energía eléctrica hacia dicha región. Estos aportes son la generación en las plantas de los embalses bajo

estudio, la generación en el resto de las plantas hidroeléctricas y térmicas de la región, y el límite máximo de transferencia a través del sistema de transmisión.

Seguidamente, se definieron las variables de decisión que se relacionan con las funciones objetivo, las que fueron generación eléctrica en la planta del embalse 1, generación eléctrica en la planta del embalse 2, generación eléctrica en el resto de la región, y límite de transferencia de energía eléctrica hacia la región de estudio a través del sistema de transmisión. Posteriormente, se consiguieron los límites de las variables de decisión, así como las restricciones que involucran a dichas variables. Los límites de operación para las cotas de los embalses se introdujeron en las restricciones, cuyas ecuaciones se encontraron utilizando regresión lineal múltiple.

Una vez que se obtuvo el modelo matemático del problema de optimización multiobjetivo, se aplicó la técnica adecuada para resolver este problema. En esta investigación se empleó el algoritmo evolutivo de optimización multiobjetivo NSGA II para conseguir un conjunto de decisiones no dominadas que definen el frente de Pareto, utilizando el lenguaje de programación Python.

Optimización multiobjetivo

Un problema de optimización multiobjetivo es aquel que tiene un conjunto de funciones objetivo por optimizar, ajustando adecuadamente los valores de las variables de decisión, las que están sometidas a un conjunto de restricciones que se deben satisfacer simultáneamente. Coello et al. (2007, p. 5) indican que “estas funciones objetivo forman la descripción matemática del criterio de desempeño, las cuales están usualmente en conflicto una con otra”. Dada la característica conflictiva entre las funciones a optimizar, no hay una solución única que pueda mejorarlas de manera simultánea, por lo que la solución del problema consiste en encontrar los valores de las funciones objetivo que sean aceptables para el que toma la decisión. Adicionalmente, Hussain & Kim (2021, p. 3) hablan de la optimización multiobjetivo como el proceso de optimizar simultáneamente un conjunto de funciones objetivo, y plantean que “en la mayoría de los casos las funciones objetivo son de naturaleza conflictiva y optimizar una de ellas implica el deterioro de la otra, y viceversa. Por consiguiente, la meta es encontrar un equilibrio entre estos objetivos en conflicto”.

Las restricciones del problema son impuestas por el medio ambiente o por limitaciones de los recursos disponibles, por lo que deben cumplirse para que una solución determinada sea considerada aceptable o factible. Por otra parte, describen dependencias entre las variables de decisión y constantes o parámetros involucrados en el problema particular.

Tal como plantean Al Shidhani et al, (2020), si se establece el vector de variables de decisión: $\mathbf{X} = (x_1, x_2, \dots, x_n)^T$, tales que satisfacen J restricciones de desigualdad, K restricciones de igualdad y están limitadas entre un límite superior y un límite inferior, y optimiza el vector de funciones objetivo, el modelo matemático genérico es:

$$\text{minimizar / maximizar } f(\mathbf{X}) = [f_1(\mathbf{X}), f_2(\mathbf{X}), \dots, f_k(\mathbf{X})]^T \quad (1)$$

Sujeto a:

$$g_i(x) \leq 0, i = 1, 2, \dots, J \quad (2)$$

$$h_j(x) = 0, j = 1, 2, \dots, K \quad (3)$$

$$x_i^L \leq x_i \leq x_i^U, \quad i = 1, 2, \dots, n \quad (4)$$


Frente óptimo de Pareto

Para cada problema de optimización multiobjetivo se podría encontrar varias soluciones de equilibrio o compromiso, las que son conocidas como soluciones óptimas de Pareto. Karami & Dariane (2022) indican que el frente de Pareto es la gráfica de las funciones objetivo considerando soluciones no dominadas, es decir, soluciones que son superiores al resto de los componentes del espacio de decisión. Una solución, como el vector de decisión, es óptima si no es dominada por ninguna otra solución en el espacio de decisión. Cuando una solución no es dominada, no es peor en ninguno de los objetivos, y es mejor en al menos uno de los objetivos. A la solución no dominada se le llama óptimo de Pareto, y al conjunto de tales soluciones compromiso óptimas se le conoce como el *conjunto óptimo de Pareto*, mientras que su imagen en el espacio de objetivos se le conoce como *frente de Pareto*.

En la Figura 1 se presentan tanto el espacio de decisión como el espacio de objetivos para el caso de un problema de optimización para el que se requiere minimizar dos funciones objetivo, y se tienen dos variables de decisión. Para efectos de ilustración, en el espacio de decisión se representan sólo tres puntos, los que se mapean hacia el espacio de objetivos. En este caso, el punto p_3 representa a una solución dominada, y los puntos p_1 y p_2 forman parte del conjunto óptimo de Pareto, y sus imágenes en el espacio de objetivos caen dentro del frente de Pareto.

Figura 1

Espacios de decisión y de objetivos




Por otra parte, en la Figura 2 se puede observar la gráfica de un frente de Pareto genérico en el que hay tres puntos característicos: el punto de utopía en el que las dos funciones alcanzan sus óptimos individuales, pero que realmente no forma parte del frente, y los dos puntos de anclaje, en los que cada función alcanza su óptimo y que sí forman parte del frente de Pareto. Estos tres puntos son definidos en Yeung & Zhang (2023), quienes además incorporan el punto *nadir*, el cual representa simultáneamente los peores valores de las funciones objetivo.

En la actualidad, para encontrar el frente de Pareto existe una variedad de técnicas. En la investigación de Emmerich & Deutz (2018) clasifican estas técnicas en tres categorías: técnicas de escalarización, algoritmos numéricos, y algoritmos evolutivos. El primer grupo consiste en agrupar las funciones objetivo en una sola (o reformular todas menos una como restricciones), y se resuelve el problema restringido a un solo objetivo. El segundo grupo reside en combinar los métodos de escalarización con los métodos numéricos matemáticos para solucionar un problema de optimización de un solo objetivo. Finalmente, el tercer grupo radica en utilizar algoritmos evolutivos, tales como los algoritmos genéticos, para resolver el problema de optimización multiobjetivo. Este tercer grupo es el que se utiliza en esta investigación, puesto que, como indican Zitzler et al. (2004), la generación del frente de Pareto podría ser muy costosa computacionalmente hablando, e incluso podría no ser factible su

obtención, dependiendo de la complejidad de la aplicación. Por esta razón, se ha hecho uso de los algoritmos evolutivos para obtener la aproximación de dicho frente.

Figura 2

Frente de Pareto genérico



Optimización multiobjetivo evolutiva

Los algoritmos evolutivos multiobjetivo (MOEA) son un tipo de métodos de optimización estocásticos que simulan el proceso de selección natural. A partir de la década de los setenta del siglo XX, se han propuesto una variedad de metodologías evolutivas, y de acuerdo con Zitzler et al. (2004) estas metodologías trabajan sobre un conjunto de soluciones candidatas, el cual es modificado a través de dos principios básicos: selección y variación. La selección imita la competencia por la reproducción y los recursos entre los seres vivos, y la variación imita la capacidad natural de crear “nuevas” formas de vida mediante la recombinación y la mutación.

Los autores mencionados establecen que un algoritmo evolutivo se caracteriza por poseer tres elementos principales: un conjunto de soluciones candidatas, un proceso de selección (*mating*) aplicado al conjunto de soluciones candidatas, y un proceso de recombinación para generar nuevas soluciones. Haciendo analogía con la evolución natural, a las soluciones candidatas se les llama individuos, y al conjunto de soluciones candidatas se les llama población. El proceso de selección, por lo general, consta de dos etapas: adaptabilidad (*fitness*) y muestreo (*sampling*).

En la primera etapa, los individuos en la población actual se evalúan en el espacio de objetivos y entonces se le asigna un valor escalar llamado adaptabilidad, el cual refleja su calidad. Posteriormente, se realiza la etapa de muestreo en la que se seleccionan individuos de la población de acuerdo con sus valores de adaptabilidad, y se colocan en una “piscina de apareamiento” (*mating pool*). Un método de muestreo comúnmente utilizado consiste en elegir aleatoriamente dos individuos de la población, y aquel que tenga mejor valor de adaptabilidad se copia en la piscina. Este procedimiento se repite hasta que la piscina esté llena.

Seguidamente se aplican los operadores de variación a los individuos ubicados en la piscina; generalmente, son los operadores de mutación y de recombinación. El operador de recombinación toma un cierto número de individuos (padres) y crea un número predefinido de hijos, al combinar partes de los padres. Asociado a este operador se tiene una probabilidad de cruce. Por otra parte, el operador de mutación modifica a los individuos al cambiar pequeñas partes de ellos en el vector asociado, y de acuerdo con una tasa de mutación dada. Se podría dar el caso que algunos individuos sean solo una copia de la solución previamente generada debido al efecto aleatorio del proceso.

Por último, se tiene el proceso de selección ambiental, en el que se determina cuales individuos de la población y de la piscina modificada formarán la nueva población. Un criterio es utilizar la piscina modificada como nueva población; otro enfoque consiste en combinar ambos conjuntos y luego escoger los mejores individuos, aunque estos no son los únicos dos enfoques utilizados normalmente.

Coello et al. (2007) clasifican los algoritmos MOEA en tres tipos: funciones de agrupamiento, enfoques basados en población, y enfoques basados en Pareto. El enfoque basado en Pareto consiste en un esquema de selección asentado en el concepto de optimalidad de Pareto. Utiliza el concepto de *fitness* para mantener la diversidad, y evitar la convergencia del algoritmo genético a una solución simple. Según Coello et al. (2007) este enfoque se puede dividir en dos generaciones: una primera generación caracterizada por el uso de la capacidad de adaptación combinada con un ranking de Pareto; y una segunda generación que surge con la introducción del concepto de elitismo. El elitismo, usualmente, se refiere al uso de una población externa para retener las soluciones no dominadas. Esta población también es llamada población secundaria. Algunos de los MOEA'S más representativos de esta segunda generación son: algoritmo evolutivo de Pareto de fuerza (SPEA), algoritmo evolutivo de Pareto de fuerza 2 (SPEA2), algoritmo genético de clasificación no dominado II (NSGA II), algoritmo genético de Pareto con nicho 2 (NPGA II).

El algoritmo NSGA consiste en hacer una jerarquización de la población sobre la base de la no dominación, antes de hacer la selección. Todos los individuos no dominados se clasifican en una categoría con un valor de adaptabilidad proporcional al tamaño de la población, para así suministrar un potencial reproductivo idéntico para estas soluciones. Para mantener la diversidad de la población, se efectúa una repartición de adaptabilidad entre estos individuos clasificados, utilizando los valores arbitrarios de adaptabilidad previamente definidos. Luego, este grupo de soluciones clasificadas se ignora, y se considera otra capa de individuos no dominados. Este proceso se repite hasta que todos los individuos en la población estén clasificados. NSGA II es una versión revisada del algoritmo NSGA de primera generación. Es computacionalmente más eficiente, utiliza elitismo, y un operador de comparación de llenado para mantener la diversidad sin especificar ningún parámetro adicional. No utiliza memoria externa, su mecanismo de elitismo consiste en la combinación de los mejores parientes con los mejores descendientes obtenidos.

Regresión Lineal Múltiple

Este es un algoritmo de aprendizaje automático supervisado, y utiliza una serie de variables explicativas o regresoras que definen el comportamiento de una variable objetivo. Se dice que el modelo es lineal en los parámetros (coeficientes) y no necesariamente en las variables. Sí se tienen k variables explicativas, según lo planteado por Gujarati & Porter (2010), la expresión de la variable objetivo se presenta a continuación:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \epsilon_i \quad (5)$$

En la ecuación (5) se cumple que Y_i es la variable objetivo, $X_{1i} \dots X_{ki}$ son las variables explicativas o regresoras, ϵ_i es el término de perturbación estocástica, e i la i -ésima observación del conjunto de datos. Asimismo, β_0 es el valor promedio de la variable objetivo cuando todas las predictoras valen cero, y $\beta_1 \dots \beta_k$ son los coeficientes de regresión.

De acuerdo con Gujarati & Porter (2010), en términos generales, existen tres métodos de estimación de los coeficientes de regresión, también llamados parámetros: mínimos

cuadrados ordinarios, máxima verosimilitud, método de los momentos, y su extensión, el método de los momentos generalizado. Usualmente se utiliza el primero de ellos, es decir, el método de los mínimos cuadrados ordinarios.

Adicionalmente, plantean que el modelo de regresión lineal se basa en ciertos supuestos; por ejemplo: no hay colinealidad exacta o cuasi exacta entre las variables explicativas, el término de perturbación estocástica está normalmente distribuido, el número de observaciones debe ser mayor al número de parámetros a estimar, el modelo de regresión es lineal en los parámetros, el valor medio de la perturbación estocástica es nulo, entre otros.

Resultados y Discusión

A continuación, se presentan y discuten los resultados obtenidos, los que incluyen el desarrollo del modelo del problema de optimización multiobjetivo, y el frente de Pareto conseguido luego de aplicar el algoritmo NSGA II utilizando el lenguaje de programación Python.

Modelo del problema multiobjetivo

La función F_1 corresponde a la minimización de la generación de las plantas hidroeléctricas asociadas a los embalses 1 y 2 (ver ecuación 6), es decir, se minimiza la sumatoria de la generación de los dos embalses. Por otra parte, la función F_2 corresponde a la minimización del racionamiento eléctrico en la región donde se ubican los embalses (ver ecuación 7). Se considera la demanda máxima histórica, la que corresponde a la hora 20 del día.

En cuanto a la operación de los generadores de los embalses 1 y 2, se tomaron los límites operativos históricos durante el período 2021-2023. Para la planta del embalse 1 una generación entre 0 MW y 185 MW, para la planta del embalse 2 una generación entre 0 y 201 MW. Para el resto de las plantas de generación hidrotérmicas de la zona, se espera una generación global entre los 300 MW y los 700 MW. Para el límite de transferencia hacia la zona, los valores se fijan entre los 200 MW y los 400 MW.

Para las cotas de los embalses, el límite de operación mínima de cada uno de ellos se considera como una restricción. Para ello, se genera una relación lineal entre la cota respectiva como variable objetivo y las variables de decisión como las variables explicativas, a través de un modelo de regresión lineal múltiple, obteniéndose dos ecuaciones de restricción asociadas a las cotas de los embalses, ver ecuación 12 para embalse 1 y ver ecuación 13 para el embalse 2. El modelo de regresión para la cota del embalse 1 tuvo un R^2 de 59%, y un error porcentual absoluto medio (MAPE) de 1,1% en los datos de prueba. En cuanto al modelo de regresión para la cota del embalse 2 tuvo un R^2 de 53%, y un MAPE de 0,43% en los datos de prueba.

Finalmente, el modelo quedaría de la siguiente manera:

$$F_1: \min (x_1 + x_2) \quad (6)$$

$$F_2: \min (1400 - x_1 - x_2 - x_3 - x_4) \quad (7)$$

Sujeto a:

$$0 \leq x_1 \leq 185 \quad (8)$$

$$0 \leq x_2 \leq 201 \quad (9)$$

$$300 \leq x_3 \leq 700 \quad (10)$$

$$200 \leq x_4 \leq 400 \quad (11)$$

$$0,0813 \cdot x_2 - 0,013 \cdot x_3 - 0,055 \cdot x_4 + 32,67 \geq 0 \quad (12)$$

$$0,0316 \cdot x_1 - 0,007 \cdot x_3 - 0,025 \cdot x_4 + 15,08 \geq 0 \quad (13)$$

Donde:

x_1 : Potencia generada de la planta 1, en MW.

x_2 : Potencia generada de la planta 2, en MW.

x_3 : Potencia promedio horaria generada del resto de las plantas, en MW.

x_4 : Límite de transferencia a través del sistema de transmisión, en MW.


Frente de Pareto

Previo a la corrida del algoritmo NSGA II, se procedió a hacer su parametrización, quedando un tamaño de la población igual a 100, un total de 1000 generaciones, una probabilidad de cruce igual a 0,9, una probabilidad de mutación igual al inverso del número de variables de decisión, el operador de cruce del tipo “binario simulado”, un operador de mutación polinómico, y la inicialización del tipo “hipercubo latino”.

Luego de aplicar el algoritmo, se obtuvo el frente de Pareto que se presenta en la Figura 3. Se puede ver que el punto de utopía corresponde a la solución trivial cuando hay generación nula en las plantas de los embalses 1 y 2, y toda la demanda es satisfecha con la generación del resto de las plantas, más lo que se transfiere a través del sistema de transmisión.

Figura 3

Frente de Pareto



De la Figura 3 también se puede observar que el punto de anclaje superior corresponde a una generación nula en los embalses 1 y 2 y un racionamiento de 300 MW, así como una generación del resto de las plantas de 700 MW y un límite de transferencia de 400 MW. El punto de anclaje inferior comprende una generación de 298,12 MW en las plantas de los embalses y un racionamiento de 2,01 MW. La generación de la planta del embalse 1 sería de 118,51 MW, la del embalse 2 de 179,6 MW, la del resto de las plantas 700 MW, y el límite de transferencia en 400 MW.

Entre los dos puntos de anclajes hay adicionalmente 76 puntos no dominados que completan el frente de Pareto. Este es un número considerable de soluciones no dominadas, lo que da flexibilidad para la administración de los embalses. Por ejemplo, en Jena et al. (2022) se obtienen sólo 20 soluciones no dominadas al utilizar el algoritmo NSGA II, al igual que en la investigación de (Hojjati et al. (2018) cuando utilizan el mismo algoritmo de optimización.

Para la aplicación del algoritmo NSGA II al problema de optimización, se utilizó el *framework* de computación evolutiva Platypus con el lenguaje Python, y el tiempo de obtención del frente de Pareto fue de aproximadamente 4,55 segundos.

Conclusiones

Se desarrolló un modelo de optimización multiobjetivo para minimizar la producción de energía eléctrica de las plantas hidroeléctricas asociadas a dos embalses, y simultáneamente minimizar el racionamiento eléctrico en la región que es alimentada en parte por las plantas de los embalses mencionados. El modelo considera el cumplimiento de las cotas mínimas y máximas de operación de los embalses como restricciones del modelo, cuyas expresiones matemáticas se encontraron utilizando el algoritmo de aprendizaje automático regresión lineal múltiple.

Luego de aplicar el algoritmo NSGA II, se encontró el frente de Pareto del problema de optimización multiobjetivo. Este frente cuenta con un total de setenta y ocho puntos de soluciones no dominadas, incluyendo los dos puntos de anclaje. Estas soluciones se pueden considerar para la operación de las plantas asociadas a los embalses bajo estudio, para las horas del día en las que se espera un mayor valor de la demanda eléctrica. El tiempo que toma obtener el frente de Pareto utilizando el lenguaje Python y el *framework* Platypus fue de sólo 4,55 segundos.

Se recomienda comparar los resultados obtenidos utilizando otros algoritmos de optimización multiobjetivo, y seleccionando los indicadores idóneos para evaluar el desempeño de cada algoritmo utilizado. Asimismo, incorporar restricciones de costos monetarios y ambientales asociados a las plantas térmicas del resto de la generación eléctrica de la región. Finalmente, se aconseja incorporar una técnica de toma de decisiones multicriterio para la selección del mejor punto del frente de Pareto obtenido.

Referencias

- Agencia Internacional de Energía. (2021). *Climate Impacts on Latin American Hydropower*. France: IEA.
- Ahmad, M., Beddu, S., Itam, Z., & Ismail Alanimi, F. (2019). State of the Art Compendium of Macro and Micro Energies. *Advances in Science and Technology Research Journal*, 88-109. <https://doi.org/10.12913/22998624/103425>.
- Al Shidhani, T., Ioannou, A., & Falcone, G. (2020). Multi-Objective Optimisation for Power System Planning Integrating Sustainability Indicators. *MDPI Energies*, <https://doi.org/10.3390/en13092199>.
- Coello Coello, C., Lamont, G., & Van Veldhuizen, D. (2007). *Evolutionary Algorithms for Solving Multi-Objective Problems*. New York, USA: Springer.
- Emmerich, M., & Deutz, A. (2018). A tutorial on multiobjective optimization: fundamentals and evolutionary methods. *Natural Computing*, 585-609. <https://doi.org/10.1007/s11047-018-9685-y>.
- Gujarati, D., & Porter, D. (2010). *Econometría*. México, D. F.: McGraw-Hill/Interamericana Editores, S.A. DE C.V.
- Hojjati, A., Monadi, M., Faridhosseini, A., & Mohammadi, M. (2018). Application and comparison of NSGA-II and MOPSO in multi-objective optimization of water resources systems. *Journal of Hydrology and Hydromechanics*, 323-329. <https://doi.org/10.2478/johh-2018-0006>.

- Huang, G., Tan, M., Meng, Z., Yan, J., Chen, J., & Qu, Q. (2023). Hydropower Scheduling with Power Load Prediction: Optimizing Energy Efficiency and Navigation Performance. *Research Square*, <https://doi.org/10.21203/rs.3.rs-2959078/v1>.
- Hussain, A., & Kim, H.-M. (2021). Evaluation of Multi-Objective Optimization Techniques for Resilience Enhancement of Electric Vehicles. *MDPI Electronics*, <https://doi.org/10.3390/electronics10233030>.
- Jena, C., Guerrero, J., Abusorrah, A., & Al-Turk, Y. (2022). Multi-Objective Generation Scheduling of Hydro-Thermal System Incorporating Energy Storage With Demand Side Management Considering Renewable Energy Uncertainties. *IEEE Access*, 52343-52357. <https://doi.org/10.1109/ACCESS.2022.3172500>.
- Karami, F., & Dariane, A. (2022). A review and evaluation of multi and many-objective optimization: Methods and algorithms. *Global Journey of Ecology*, 104-119. <https://dx.doi.org/10.17352/gje.000070>.
- Li, F.-F., & Qiu, J. (2015). Multi-Objective Reservoir Optimization Balancing Energy Generation and Firm Power. *Energies*, 6963-6976. <https://doi.org/10.3390/en8076962>.
- López, M. (11 de Febrero de 2024). ¿Qué pasa con los fenómenos de El Niño y La Niña y cómo esto afecta a Venezuela? *Efecto Cocuyo*, págs. Recuperado de: <https://efectococuyo.com/cambio-climatico/que-pasa-con-los-fenomenos-de-el-nino-y-la-nina-venezuela/>.
- Marcelino, C., Leite, G., Delgado, C., de Oliveira, L., Wanner, E., Jiménez-Fernández, S., & Salcedo-Sanz, S. (2021). An efficient multi-objective evolutionary approach for solving the operation of multi-reservoir system scheduling in hydro-power plants. *Expert Systems With Applications*, <https://doi.org/10.1016/j.eswa.2021.115638>.
- National Oceanic and Atmospheric Administration. (8 de Febrero de 2024). EL NIÑO/SOUTHERN OSCILLATION (ENSO) DIAGNOSTIC DISCUSSION. *Climate Prediction Center*, pág. Recuperado de: https://www.cpc.ncep.noaa.gov/products/analysis_monitoring/enso_advisory/ensodisc.shtml.
- Okoye, G., Kassem, Y., & Gökçekuş, H. (2023). Assessing the impacts of climate change on hydropower generation and the power sector in Nigeria. *China Petroleum Processing and Petrochemical Technology*, 1-15.
- REN21. (2023). *Global Status Report - Renewables 2023*. París: REN21 Secretariat.
- Sun, X., Luo, J., & Xie, J. (2018). Multi-Objective Optimization for Reservoir Operation Considering Water Diversion and Power Generation Objectives. *MDPI Water*, <https://doi.org/10.3390/w10111540>.
- Wei, N., Yang, F., Lu, K., Xi, J., & Zhang, S. (2022). A Method of Multi-Objective Optimization and Multi-Attribute Decision-Making for Huangjinxia Reservoir. *MDPI Applied Sciences*, <https://doi.org/10.3390/app12136300>.
- Yeung, D., & Zhang, Y. (2023). Bi-Objective Optimization: A Pareto Method with Analytical Solutions. *Applied Mathematics*, 57-81. <https://doi.org/10.4236/am.2023.141004>.
- Zhou, E., Liu, X., Meng, Z., Yu, S., Mei, J., & Qu, Q. (2023). Optimizing Hydropower Station Scheduling: A Multi-Objective Real-Time Approach. *Scientific Reports*, <https://doi.org/10.21203/rs.3.rs-3009681/v1>.
- Zitzler, E., Laumanns, M., & Bleuler, S. (2004). A Tutorial on Evolutionary Multiobjective Optimization. En X. Gandibleux, M. Sevaux, K. Sörensen, & V. T'kindt, *Metaheuristics for Multiobjective Optimisation* (págs. 3-37). Berlin: Springer. https://doi.org/10.1007/978-3-642-17144-4_1.