

UCUENCA

Universidad de Cuenca

Facultad de Ingeniería

Carrera de Ingeniería de Sistemas

Aplicación de métodos heurísticos para optimizar la distribución de agua: un estudio de caso para la cuenca del río Machángara, Ecuador

Trabajo de titulación previo a la obtención del título de Ingeniera de Sistemas

Autor:

Berenice Magdalena Guerrero Guamán

Director:

Jaime Eduardo Veintimilla Reyes

ORCID: 0000-0003-0409-9602

Cuenca, Ecuador

2023-02-01

Resumen

El agua se puede representar por un nexo llamado WEF-Nexus que incluye suministro de agua, tratamiento de aguas residuales y generación de energía hidroeléctrica en un sistema de agua con reservorios (Liu et al., 2018). El factor WEF-Nexus considera: evitar inundaciones, cumplir con demandas de agua y mantener el nivel de agua en reservorios y segmentos de río. La optimización de la distribución de agua considerando este factor puede ser abordada con programación lineal, no lineal, dinámica-discreta y heurística. En (Veintimilla-Reyes et al., 2019), el autor aplicó programación lineal para la optimización de la distribución del agua en la cuenca del río Machángara, y este estudio busca la optimización en ese mismo contexto, pero aplicando métodos heurísticos. El modelo heurístico implementado es PSO (particle swarm optimization), que fue seleccionado luego de una revisión sistemática de literatura. Se consideran tres fases: calibración, validación y aplicación. La primera fase calibra variables necesarias para que el modelo reproduzca la realidad con datos de 1998-2001. Se valida comparando la salida del modelo parametrizado con los valores esperados en el período 2002-2003. Finalmente, se aplica el modelo para distribuir el agua óptimamente en el período 2004-2005. Los datos usados fueron facilitados por el Programa para el Manejo del Agua y del Suelo de la Universidad de Cuenca (Promas, 2022). De los resultados destaca que PSO y el paquete Pymoo (usado para la implementación) presentan dificultad para encontrar una solución que pueda satisfacer todas las restricciones. También se usa PSO para determinar el número óptimo de reservorios, pero el modelo sufre del mismo impedimento en satisfacer restricciones. Para trabajos futuros se plantea la implementación de algoritmos híbridos, y reducir el número de restricciones y variables.

Palabras clave: optimización, métodos heurísticos, distribución del agua en un sistema de río con reservorios, río Machángara

Abstract

Water can be represented by a nexus called WEF-Nexus that includes water supply, wastewater treatment and hydroelectric power generation in a reservoir water system (Liu et al., 2018). The WEF-Nexus factor considers: avoiding floods, meeting water demands and maintaining the water level in reservoirs and river segments. The optimization of water distribution considering this factor can be approached with linear, non-linear, dynamic-discrete and heuristic programming. In (Veintimilla-Reyes et al., 2019), the author applied linear programming to optimize the distribution of water in the Machángara river basin, and this study seeks optimization in that same context, but applying heuristic methods. The implemented heuristic model is PSO (particle swarm optimization), which was selected after a systematic literature review. Three phases are considered: calibration, validation and application. The first phase calibrates variables necessary for the model to reproduce reality with data from 1998-2001. It is validated by comparing the output of the parameterized model with the expected values in the 2002-2003 period. Finally, the model is applied to optimally distribute water in the 2004-2005 period. The data used were provided by the Program for Water and Soil Management of the University of Cuenca (Promas, 2022). From the results it stands out that PSO and the Pymoo package (used for the implementation) present difficulties in finding a solution that can satisfy all the constraints. PSO is also used to determine the optimal number of reservoirs, but the model suffers from the same handicap in satisfying constraints. For future work, the implementation of hybrid algorithms is proposed, and reduce the number of restrictions and variables.

Keywords: optimization, heuristic methods, distribution of water in a river system with reservoirs, Machángara river

Índice

Resumen.....	2
Abstract.....	3
Índice	4
Índice de Figuras	7
Índice de Tablas	8
Agradecimientos	9
Simbología	11
1. Introducción.....	12
1.1. Motivación y contexto	12
1.1.1. Contexto sobre el área de estudio.	13
1.2. Planteamiento del problema.	14
1.3. Objetivos	15
1.3.1. Objetivo General.....	15
1.3.2. Objetivos Específicos	15
1.4. Metodología	16
1.5. Estructura del trabajo.....	17
2. Marco Teórico	19
2.1. Conceptos relacionados al área de estudio	19
2.1.1. La cuenca del río Machángara.....	19
2.1.2. Reservorios, producción de energía eléctrica y otros usos del agua.....	21
2.2. Conceptos relacionados a los métodos heurísticos.....	22
2.2.1. Water Allocation Problems (Problemas de asignación de agua)	22
2.2.2. Heurísticas y Metaheurísticas.	23
3. Estado del arte.	26
3.1. Trabajos relacionados.....	26
3.2. Revisión de literatura de los métodos heurísticos para resolver este tipo de problemas.	27
3.2.1. Introducción.	27
3.2.2. Materiales y Métodos.	27
3.2.3. Resultados y Discusión.	30
3.2.4. Conclusiones	38

4.	Materiales y Métodos.....	40
4.1.	Los datos hidrológicos de la cuenca del río Machángara.....	40
4.2.	Modelamiento hidrológico.....	41
4.3.	Selección de las variables y restricciones a considerar dentro del modelamiento. 44	
4.4.	Selección de los métodos heurísticos.....	45
4.4.1.	PSO (Particle Swarm Optimization).....	46
4.4.2.	Manejando Restricciones en PSO.....	50
4.5.	Modelamiento del problema.....	51
4.5.1.	Paralelización.....	52
4.5.2.	Manejo de restricciones.....	52
4.5.3.	Hiperparámetros de PSO.....	53
4.5.4.	Modelamiento en PSO para el número de reservorios óptimo de acuerdo al problema planteado.....	54
4.6.	Calibración, validación y aplicación del modelo.....	57
4.6.1.	Calibración.....	59
4.6.2.	Validación.....	62
4.6.3.	Aplicación.....	63
4.7.	Definición de los indicadores estadísticos para poder comparar los resultados de cada modelo.....	67
5.	Resultados y discusión.....	68
5.1.	Comparación.....	68
5.2.	Resultados del número de reservorios óptimo con PSO.....	73
6.	Conclusiones y Recomendaciones.....	75
6.1.	Conclusiones.....	75
6.2.	Trabajos futuros.....	75
	Referencias.....	77
	Anexos.....	84
	Anexo A: Modelo matemático para la distribución del agua en la cuenca del río Machángara.....	84
	Anexo B: Artículo científico publicado de la revisión de literatura.....	89
	Introduction	89
	Materials and Methods	90
	Results and Discussion	91

Research Questions	91
Conclusions	96
References	96
Anexo C: Implementación en Pymoo para PSO.....	97

Índice de Figuras

Fig. 1. Cuenca del río Machángara en el sur de Ecuador (Veintimilla-Reyes et al., 2019).	20
Fig. 2. Distribución del uso del suelo en la cuenca del río Machángara (Veintimilla-Reyes et al., 2019).....	21
Fig. 3. Framework general de los algoritmos genéticos descrito en (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan Hilton, et al., 2010)	25
Fig. 4. Parte de la clasificación de los algoritmos heurísticos por (Kumar & Yadav, 2022)	31
Fig. 5. Histograma de los métodos heurísticos utilizados en los artículos revisados.	31
Fig. 6. Configuración de red fluvial para la cuenca Machángara.	41
Fig. 7. La configuración final de la red del sistema fluvial Machángara (Veintimilla-Reyes et al., 2019).....	43
Fig. 8. Penalizaciones y parámetros con su valor asignado para este caso de estudio (Veintimilla-Reyes et al., 2019). Los valores de los parámetros se calibrarán.	45
Fig. 9. Manejo de valores de hiperparámetros por parte de Pymoo.	54
Fig. 10. Representación gráfica de la configuración de red utilizadas en (Veintimilla-Reyes et al., 2019) y también como base para construir PSO. (Izquierda) Configuración de red base. (Derecha) Configuración de red con todos los nodos como transferencia de nodos candidatos.	55
Fig. 11. Restricciones agregadas para el caso de los reservorios candidatos (Veintimilla-Reyes et al., 2019).	56
Fig. 12. Ramas de la cuenca del río Machángara utilizados para la calibración (Veintimilla-Reyes et al., 2019).	60
Fig. 13. Casos de uso aplicados en (Veintimilla-Reyes et al., 2019), y también usados para la prueba y error con PSO.....	61
Fig. 14. Desviación cuadrática media [$\text{hm}^3/\text{día}$] entre el flujo de agua simulado en ArcSWAT (referencia) y el flujo de agua simulado por el modelo PSO utilizando los parámetros por defecto para el período 1998-2001.	62
Fig. 15. Desviación cuadrática media [$\text{hm}^3/\text{día}$] entre el flujo de agua simulado en ArcSWAT (referencia) y el flujo de agua simulado por el modelo LP utilizando los parámetros por defecto para el período de tiempo 2004-2005.	63
Fig. 16. Volumen de agua almacenada en los reservorios.	65
Fig. 17. Penalidades en el período 2004-2005.	66

Índice de Tablas

Tabla 1. Demandas que debe cubrir la optimización de la cuenca del río Machángara.....	14
Tabla 2. Criterios de búsqueda para la revisión sistemática de la literatura	28
Tabla 3. Agua diaria requerida por los nodos de demanda (Promas, 2022).....	42
Tabla 4. Numero de variables, restricciones de igualdad y restricciones de desigualdad para cada etapa del problema.	52
Tabla 5. Características de los embalses existentes y candidatos	57
Tabla 6. Parámetros del modelo y los valores por defecto asignados	58
Tabla 7. Agua diaria requerida por los nodos de demanda (Promas, 2022).	63
Tabla 8. Capacidades de cada reservorio en la cuenca del río Machángara.	64
Tabla 9. Desviación del volumen de agua pretendido respecto del volumen conseguido tras la optimización (hm ³) y penalizaciones asociadas (€)	66
Tabla 10. Promedio y RMSD de las restricciones para calibración. El valor de cero indica que no se viola ninguna restricción.	68
Tabla 11. Promedio y RMSD de las restricciones para validación. El valor de cero indica que no se viola ninguna restricción.	69
Tabla 12. Promedio y RMSD de las restricciones para ejecución. El valor de cero indica que no se viola ninguna restricción.	70
Tabla 13. RMSD para cada etapa y por método.	71
Tabla 14. Comparación de valores de penalidad para LP vs PSO.	72
Tabla 15. Reservorios construidos por PSO como mejor opción para reducir la penalidad.	73
Tabla 16. Construcción y mantenimiento de un solo reservorio y la penalidad de las demandas no satisfechas.	74

Agradecimientos

A mi director de tesis, Ing. Jaime Veintimilla, por su apoyo, paciencia y guía a lo largo de todo el proceso, sin las cuales este trabajo de titulación no habría salido adelante.

A los docentes de la Facultad de Ingeniería de la Universidad de Cuenca, por brindar las herramientas y conocimientos para el desarrollo de esta tesis, así como para el crecimiento dentro del área profesional.

Al Programa para el Manejo del Agua y del Suelo de la Universidad de Cuenca – PROMAS que facilitaron los datos de la cuenca del río Machángara para el desarrollo de esta tesis.

Al vicerrectorado de Investigación de la Universidad de Cuenca por su apoyo financiero y académico en la conferencia TICEC 2022 en la que se presentó el paper producto de esta tesis, titulado “Optimization Models Used in Water Allocation Problems in River Basin with Reservoirs: A Systematic Review”.

A mis familiares y amigos, por su apoyo y motivación.

Berenice

Dedicatoria

Dedicado a mi abuelita Magdalena, quien ha sido una de las personas más importantes de mi vida y mi modelo a seguir. Me enseñó lo que es la perseverancia; y con sus historias y anécdotas me preparó para la vida y todos los retos que vendrían.

Dedicado a mis padres, Jhonson e Iris, que con sus consejos y sabias palabras me guiaron y enseñaron que era capaz de mucho más. Me enseñaron que la perseverancia y disciplina vence los talentos innatos, que se quedan en la nada si no se trabaja y mejora cada día.

Dedicado a mis hermanos Bessie, José y Ezequiel, que con sus ocurrencias y compañía alumbraron mi vida y me inspiraron a seguir trabajando y convertirme en la persona que soy ahora.

Dedicado a mi abuelita Mariana, mis tías Jamileth, Zandra, Gloria, Katty y mi tío Pedro, quienes siempre me apoyaron en cada etapa de mi vida e inculcaron el estudio como una parte importante de mi vida.

Dedicado a mi mejor amiga, Evelyn Ochoa, con quien aprendí que la amistad puede superar las distancias y el tiempo, con quien aprendí que la familia va más allá de la sangre. Quien soporto mis quejas, fracasos y victorias de la manera más genuina.

Dedicado a mis mejores amigos, Daniel Seaman y Marcelo Peñafiel; con quienes compartí mi vida universitaria y la llenaron de color en cada momento. Con quienes crecí como persona y aprendí mucho más de la vida.

Berenice

Simbología

ArcSWAT: ArcGIS - ArcView extension for SWAT

GA: Genetic Algorithm

GWD4S: Global Weather Dataset for SWAT

LP: Linear Programming

MADM: Multi Attribute Decision Making

MCDM: Multi Criteria Decision Making

MILP: Mixed Integer Linear Programming

MODM: Multiple Objective Decision Making

NFO-LP: Network Flow Optimization – Linear Programming model

NFO-MILP: Network Flow Optimization – Mixed Integer Linear Programming model

PSO: Particle Swarm Optimization

Pymoo: Multi-objective Optimization in Python

SWAT: Soil and Water Assessment Tool

WEF-nexus: Water, Energy and Food Nexus

WSN: Water Supply Network

1. Introducción

1.1. Motivación y contexto

El agua, la energía y los alimentos están íntimamente relacionados, y esta relación recibe el nombre de WEF-Nexus (water-energy-food Nexus). El nexo incluye el suministro de agua, el tratamiento de aguas residuales y la generación de energía hidroeléctrica en un sistema de agua con reservorios (Liu et al., 2018). El diseño óptimo de un sistema de distribución de agua que cumpla con este nexo se ha convertido en un tema de investigación urgente (Yang et al., 2018). La distribución de agua en una cuenca de río con reservorios puede optimizarse para satisfacer las demandas de diferentes nodos(puntos) que buscan cumplir con el WEF-Nexus. Este problema de optimización se puede abordar con diferentes métodos como programación lineal (LP), programación lineal de enteros mixtos (MILP), métodos heurísticos y meta-heurísticos.

Una forma de representar el sistema de distribución de agua es a través de una red de nodos y arcos. La optimización de dicha red se conoce como Network Flow Optimization(NFO) (Haro et al., 2012). En (Veintimilla-Reyes et al., 2019), el autor utilizó un modelo de programación lineal sobre NFO (NFO-LP) para la optimización de la distribución de agua en la cuenca del río Machángara, considerando también los reservorios. Luego, dentro del mismo estudio, el autor utiliza una extensión del modelo NFO-LP para transformarlo en un modelo de programación lineal mixto de optimización del flujo en una red (NFO-MILP). Esta extensión permite incorporar variables de decisión binarias en la función objetivo para indicar la selección (o no) de un nodo como un reservorio candidato. Cabe mencionar que los sistemas de programación matemática, como NFO-LP, requieren altos consumos computacionales dependiendo de la dimensión de la red. Los modelos de LP y MILP son aplicados sobre la cuenca del río Machángara para determinar la distribución óptima del agua en esta cuenca de tal manera que logre cumplir con las demandas de agua para el consumo humano, riego, equilibrio ambiental y plantas hidroeléctricas. Y para cumplir con el WEF-Nexus también se considera el evitar inundaciones y mantener el nivel de agua requerido en reservorios y segmentos de río.

Como se mencionó anteriormente, no solo se puede solucionar este tipo de problemas con los métodos de LP y MILP, sino también se puede resolver con los métodos heurísticos y meta-heurísticos. A diferencia de la programación lineal que busca entregar una solución exacta, que

puede terminar en un óptimo local antes que un global (Lindfield & Penny, 2019), los métodos heurísticos pueden encontrar una aproximación a la solución óptima global. Es por esta razón que se propone solucionar el modelo matemático planteado por (Veintimilla-Reyes et al., 2019) para la distribución del agua en la cuenca del río Machángara pero aplicando un modelo heurístico o meta-heurístico. Para elegir el modelo heurístico se plantea también una revisión de literatura con el método de Fink. Finalmente, se plantea una comparación de los resultados obtenidos por los métodos exactos de LP y MILP versus los resultados obtenidos por el método heurístico, con el objetivo de determinar que método rindió mejor para el problema planteado.

1.1.1. Contexto sobre el área de estudio.

El área de estudio es la cuenca del río Machángara, que está ubicado entre las provincias de Azuay y Cañar, las cuales pertenecen al sur del Ecuador. Forma parte del sistema hidrográfico de Santiago, ocupando un aproximado de 32.500 hectáreas (Etapa EP, 2022). Tomando como referencia la zona urbana de Cuenca, el río Machángara se ubica al noreste, donde también se encuentra la zona industrial de la ciudad. En su recorrido pasa por las parroquias de Checa, Chiquintad, Sinincay y Ricaurte (Villavicencio Riera & Chávez Ochoa, 2011). En esta cuenca se ubican dos reservorios (Chanlud y Labrado) y también dos centrales hidroeléctricas con reservorios (Saucay y Saymirin) (Veintimilla-Reyes et al., 2019). También hay una planta de tratamiento de agua potable conocida como Tixán, que entró en funcionamiento en 1997 (Etapa EP, 2022).

Los datos necesarios de esta cuenca para el estudio planteado en (Veintimilla-Reyes et al., 2019) como en este estudio son construidos con una herramienta de modelado hidrológico como SWAT (Texas A&M University, 2018) basado en información geográfica para generar la información faltante. Para ejecutarse, SWAT debe contar con varios conjuntos de datos de entrada, como un modelo de elevación digital (DEM), un mapa de suelos, un mapa de cobertura terrestre e información meteorológica. Este modelo es capaz de generar series temporales de caudales, series temporales de precipitaciones, entre otros, para las localidades de interés de la región de estudio. Se usan los datos provenientes del PROMAS (Programa para el Manejo del Agua y del Suelo de la Universidad de Cuenca), la estación meteorológica “El Labrado” y GWD4S (Global Weather Dataset for SWAT). Algunos datos son usados directa, ente mientras que otros sirven para construir nuevos datos o comparar información para re escalamiento. El pre procesamiento de los datos es detallado brevemente en las siguientes secciones y en (Veintimilla-Reyes et al., 2019) se puede encontrar este proceso con mayor detalle.

1.2. Planteamiento del problema.

La cuenca del río Machángara tiene 4 reservorios en toda su extensión y existen distintas demandas a cubrir. Basándose en el modelamiento matemático planteado en (Veintimilla-Reyes et al., 2019), en esta tesis se aborda el problema de resolver dicho modelo matemático con un método heurístico que pueda resolver problemas complejos y que haya sido usado en problemas similares para asegurar que el método aplicado tiene buenos resultados en este tipo de problemas.

Para cumplir con esto, el problema de la optimización de la distribución del agua en la cuenca del río Machángara se subdivide en dos subproblemas: encontrar que método heurístico es ideal para resolver el problema e implementar dicho método. La cuenca del río Machángara es representada a través de un NFO (Network Flow Optimization) que es una red de nodos y segmentos, y para el caso del río Machángara esta red tiene 16 nodos de transferencia (T), 4 nodos que representan los reservorios (R) y 19 segmentos de río (segmentos que conectan los nodos). Los nodos de transferencia hacen referencia a una ubicación a través de la cual el agua fluye desde un segmento anterior al segmento conectado. A esta red se agregan los nodos de demanda que representan las necesidades a cubrir por la optimización de la distribución del agua que incluyen cubrir con necesidades de consumo humano, agua de riego, generación de electricidad, entre otros. En la Tabla 1 se detalla los nodos de demanda incluidos en la cuenca del río Machángara y la cantidad de agua que debe ser distribuida.

Tabla 1. Demandas que debe cubrir la optimización de la cuenca del río Machángara

Nodo	Uso	Valor(hm³/día)
D1	Planta de energía Saucay	0.621
D2	Sistema de riego Machángara	0.043
D3	Central de Saymirin	0.691
D4	Sistema de agua potable de Tixán	0.121
D5	Sistema de riego Ricaurte	0.026
D6	Función del ecosistema	0.017

Aparte de agregar las demandas, al considerar el cumplimiento del WEF-Nexus en esta optimización, se debe tomar en cuenta también el evitar inundaciones y mantener el nivel de

agua requerido en reservorios y segmentos de río. Para lograr esto se debe dar importancia a la implementación de las restricciones del modelo matemático y que el algoritmo heurístico pueda encontrar una solución que logre cumplir con todas ellas, lo que vuelve al problema complejo debido a la cantidad de variables a manejar que incrementa la probabilidad de violación de restricciones. Dentro de las restricciones se considera:

- No cumplir con las demandas
- Exceder en las demandas
- Inundaciones de segmentos de ríos
- No cumplir con la capacidad mínima en los tramos de río
- Superar la capacidad máxima en reservorios
- No alcanzar la capacidad mínima en reservorios
- No alcanzar la capacidad mínima en los segmentos de demanda
- Superar la capacidad máxima en los segmentos de demanda

1.3. Objetivos

1.3.1. Objetivo General

Comparar y determinar si la optimización a través de métodos heurísticos para el problema de distribución de agua en la cuenca del río Machángara produce mejores resultados en comparación con la aplicación de modelos matemáticos exactos (LP/ILP/MILP) realizados en (Veintimilla-Reyes et al., 2019).

1.3.2. Objetivos Específicos

- Determinar un algoritmo heurístico aplicable a la optimización de la distribución del agua en la cuenca del río Machángara.
- Construir un modelo de optimización que permita aplicar el algoritmo heurístico seleccionado para este estudio.

- Recomendar en base al modelo de optimización si es viable construir nuevos reservorios en el sistema del río Machángara que permita obtener mejores resultados en la optimización del problema.
- Comparar los resultados del método heurístico con los modelos matemáticos exactos (LP/ILP/MILP) mediante indicadores estadísticos.

1.4. Metodología

El marco metodológico para este estudio se construye alrededor del método metodológico empleado en (Veintimilla-Reyes et al., 2019), teniendo un enfoque cuantitativo con un alcance descriptivo y de correlación. El estudio parte con una revisión de literatura de los métodos heurísticos aplicados en los problemas de asignación de recursos hídricos y afines, considerando un lapso de tiempo desde el 2015 hasta el 2021. La base de datos a consultar es Google Scholar debido al amplio uso entre investigadoras y su facilidad de acceso. El objetivo de esta revisión de literatura es seleccionar el método heurístico aplicable para el caso de estudio de la cuenca del río Machángara.

Una vez seleccionado el método heurístico, se procede con la investigación de paquetes y software que permita implementar el método heurístico para el modelo matemático planteado en (Veintimilla-Reyes et al., 2019). Es necesario considerar que dicho paquete o software permita establecer restricciones, manejo de las penalidades e incluso mejoras del algoritmo heurístico base que se seleccione.

Una vez implementado el método heurístico, se valida dicho método para el problema de la distribución del agua a través de las fases usadas con los métodos exactos de LP y MILP (Veintimilla-Reyes et al., 2019) que son: calibración, validación y aplicación. De esta manera se validan los métodos a través de las mismas fases.

a. Fase de calibración.

La fase de calibración consiste en calibrar las variables necesarias para que el modelo reproduzca la realidad lo más fielmente posible. Se aplica el proceso de prueba-error para cada una de las variables que se requiera.

b. Fase de validación.

La siguiente fase consiste en validar el modelo, para esto se compara la salida del modelo parametrizado con los valores esperados.

c. Fase de aplicación.

Finalmente, se aplica el modelo calibrado y validado para asignar de manera óptima el agua disponible a los nodos de demanda.

Para cada fase se utilizan distintos datasets pertenecientes al sistema fluvial y a la cuenca del río Machángara ubicado en la Cordillera de los Andes en el sur de Ecuador. Estos datos son facilitados por el Programa para el Manejo del Agua y del Suelo de la Universidad de Cuenca (Promas, 2022), donde ciertos datos son ingresados en la implementación directamente, mientras que otros datos sirven para construir la serie de tiempo con ArcSWAT debido a que no se cuenta con cierta información necesaria para el modelo. Para la fase de calibración y validación, los resultados esperados provienen de una serie de tiempo con ArcSWAT que fue también utilizado para calibrar y validar el modelo en (Veintimilla-Reyes et al., 2019), y abarcan los períodos de 1998-2001 y 2002-2003 respectivamente. Para la fase de aplicación se usan los datos del período 2004-2005.

Una vez desarrollado cada fase, se realiza una optimización sobre el número de reservorios que se pueden agregar en las ubicaciones de cada nodo para obtener mejores resultados. Este paso también fue realizado en (Veintimilla-Reyes et al., 2019) y servirá de objeto de comparación. Se procede luego con la sección de resultados de la optimización con el algoritmo heurístico. Estos resultados son comparados con los obtenidos en (Veintimilla-Reyes et al., 2019) con el objetivo de determinar si el algoritmo heurístico es un mejor enfoque para el problema de asignación de agua dentro de la cuenca del río Machángara.

1.5. Estructura del trabajo

Esta tesis se estructura de la siguiente manera. En la sección 2 se presenta el marco teórico donde se detallan conceptos del área de estudio de la cuenca del río Machángara, así como conceptos generales de los métodos heurísticos. En la sección 3 se indica el estado del arte que incluye una revisión de literatura sobre los métodos heurísticos y meta-heurísticos utilizados en problemas de distribución de agua para un sistema de río con reservorios. En la sección 4 se indican los Materiales y Métodos, donde se indican el origen de los datos usados en la implementación del problema, un breve resumen de las variables y restricciones con un enfoque

matemático. También se incluyen información del método heurístico seleccionado luego de la revisión de literatura, así como el modelamiento del problema considerando dicho método. En este mismo capítulo se aplican las fases de calibración, validación y aplicación; y también se definen los indicadores estadísticos que servirán para comparar los resultados del método heurístico con los resultados de los métodos exactos de LP y MILP de (Veintimilla-Reyes et al., 2019).

En la sección 5 se presenta los resultados y discusión de los mismos, donde se da enfoque a la comparación de los resultados de los métodos exactos de LP y MILP con el método heurístico. Finalmente, en la sección 6 se detallan las conclusiones y trabajos futuros.

2. Marco Teórico

En esta sección se presentan conceptos necesarios para comprender el contexto en el que se desarrollara la tesis, así como conceptos útiles para el desarrollo del problema que se planteara posteriormente. Cabe recalcar que ciertos conceptos se abordaran a mayor detalle en otras secciones, sobre todo luego de aplicar la revisión de literatura que permitirá centrarse en un método heurístico o metaheurístico para el caso de uso de esta tesis.

2.1. Conceptos relacionados al área de estudio

El área de estudio engloba la cuenca del río Machángara, que es un sistema de río con reservorios. En esta sección se aborda los conceptos generales de esta cuenca que permite conocer el contexto en el que se aplicará el método heurístico para la optimización de la distribución del agua.

2.1.1. La cuenca del río Machángara.

El río Machángara está ubicado en una cuenca andina entre las provincias de Azuay y Cañar, las cuales pertenecen al sur del Ecuador. Forma parte del sistema hidrográfico de Santiago, ocupando un aproximado de 32.500 hectáreas (Etapa EP, 2022). Tomando como referencia la zona urbana de Cuenca, el río Machángara se ubica al noreste, donde también se encuentra la zona industrial de la ciudad. En su recorrido pasa por las parroquias de Checa, Chiquintad, Sinincay y Ricaurte (Villavicencio Riera & Chávez Ochoa, 2011). En la Fig. 1 se puede observar el área que abarca la cuenca del río Machángara.

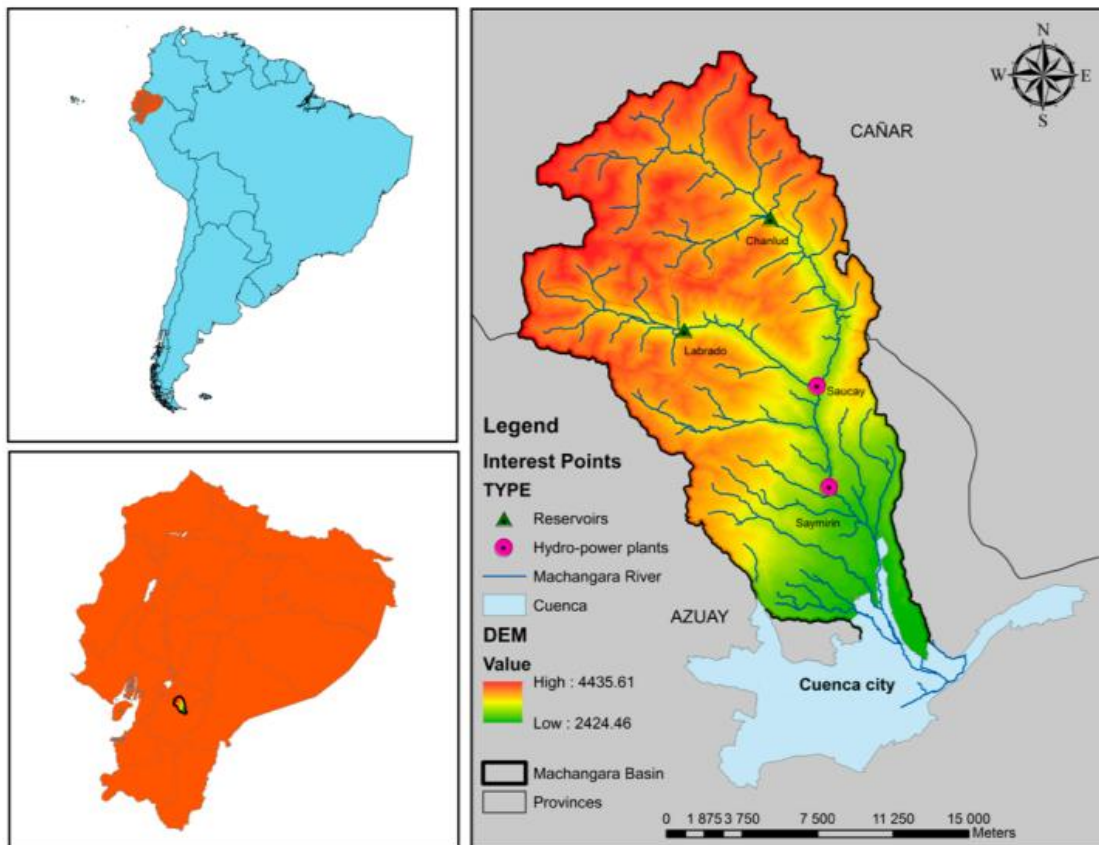


Fig. 1. Cuenca del río Machángara en el sur de Ecuador (Veintimilla-Reyes et al., 2019).

Como medida de cuidado del medio ambiente, el 77% de la cuenca del río Machángara se encuentra del área de Bosque y Vegetación Protectora Machángara – Tomebamba (Etapa EP, 2022). Aparte de ser de vital importancia para la preservación de la naturaleza, el agua de esta cuenca también sirve para cumplir con servicios múltiples como: Agua para consumo humano, generación de energía hidroeléctrica, agua de riego y agua de industrias.

En esta zona se presentan dos estaciones en el año, la primera es la estación lluviosa que abarca desde mediados de febrero hasta julio; y la estación seca predomina el resto del año (Jerves-Cobo et al., 2017). La precipitación media anual es de 3090 mm, de los cuales 2900 mm corresponden a la estación lluviosa y 190 mm a la estación seca (Veintimilla-Reyes et al., 2019). Sin embargo, las estaciones no se presentan uniformes, por lo que los valores esperados de precipitación pueden variar y afectar a los cultivos o al abastecimiento de agua.

Según PROMAS, (Promas, 2022), los usos del suelo en la cuenca del río Machángara se distribuyen de la siguiente manera: 6,4% es área poblada, 11,3% son tierras de cultivo, 0,5%

infraestructuras, 59,1% páramo (un tipo de vegetación sin árboles que se encuentra en altitudes más altas), 9,3% pasto, 1,2% bosque nativo, 4,2% plantación forestal, 6% vegetación arbustiva, 1% otra vegetación herbácea y 1% cuerpos de agua (ver en Fig. 2).

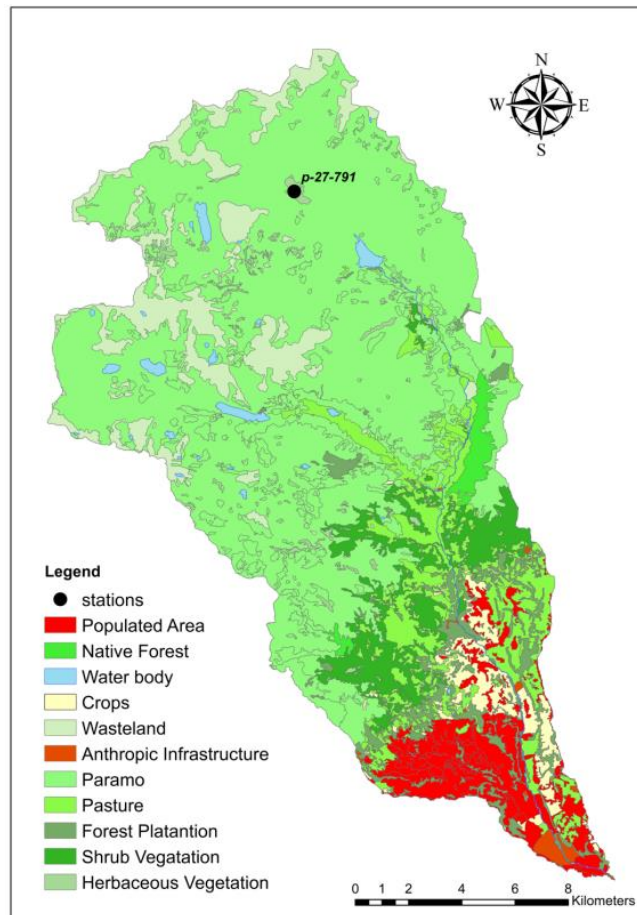


Fig. 2. Distribución del uso del suelo en la cuenca del río Machángara (Veintimilla-Reyes et al., 2019)

2.1.2. Reservorios, producción de energía eléctrica y otros usos del agua.

Como se mencionó en el apartado anterior, la inestabilidad en las estaciones indica que es necesario la existencia de reservorios. En esta cuenca se ubican dos reservorios (Chanlud y Labrado) y también dos centrales hidroeléctricas con reservorios (Saucay y Saymirin) (Veintimilla-Reyes et al., 2019). También hay una planta de tratamiento de agua potable conocida como Tixán, que entró en funcionamiento en 1997 (Etapa EP, 2022). Esta planta potabiliza un promedio de 600 litros por segundo y puede abastecer un aproximado de 140000 habitantes de Cuenca y las parroquias aledañas. Aparte de proveer agua para el consumo humano y para la generación de energía hidroeléctrica (Saucay y Saymirin), también provee agua para el sistema

de riego. Cerca de 1300 hectáreas usan este sistema de riego que favorece a unos 1900 usuarios aproximadamente (Etapa EP, 2022).

2.2. Conceptos relacionados a los métodos heurísticos.

En esta sección se pretende abordar conceptos relacionados a los métodos heurísticos que brindaran contexto para las siguientes secciones. Se da un breve resumen de lo que tratan los problemas de optimización de la distribución del agua, los algoritmos heurísticos y metaheurísticos, así como una breve explicación de dos de los algoritmos heurísticos más utilizados en los problemas de optimización de manejo de recursos hídricos en general. Cabe recalcar que el problema de distribución del agua en un sistema de río con reservorios (como es el caso de la cuenca del río Machángara) es un sub problema de los problemas de manejo de recursos hídricos.

2.2.1. Water Allocation Problems (Problemas de asignación de agua)

El agua y la energía se consideran los recursos más importantes para la vida y el desarrollo humano. En zonas donde el agua escasea junto con un aumento de la población que demanda mayor cantidad de agua para sobrevivir, la distribución del agua para cumplir con las demandas de consumo tiende a ser cada más importante.

Para poder cumplir con estas demandas, se suelen construir reservorios para un solo uso o varios usos como producción hidroeléctrica, riego, consumo, entre otros. Es dentro de este contexto que surge el problema de asignación o distribución de agua, tanto a los reservorios como a los puntos de demanda (consumo, riego). Este es un problema complejo que tiene una combinación de restricciones, políticas y mecanismos que busca permitir una buena gestión del agua y disminuir el riesgo de escasez de agua (Gebre et al., 2021). Y la distribución del agua puede ser optimizada para cumplir con las demandas de agua de una manera eficaz y hasta económica.

Uno de los métodos usados dentro de este tipo de problemas complejos de optimización se conoce como MCDM (Multi-Criteria Decision-Making Methods) (Gebre et al., 2021), que son métodos de decisión. Estos métodos a su vez se subdividen en MADM (multi-attribute decision-making) y MODM (multiple-objective decision-making). Para el problema de la optimización de la distribución del agua es importante los métodos MODM, que agrupan a los modelos de programación matemática y a los algoritmos heurísticos. Dentro de los modelos matemáticos se

puede destacar a la programación lineal y no lineal, la programación lineal entera mixta, entre otros. Los métodos heurísticos serán descritos en la siguiente sección.

2.2.2. Heurísticas y Metaheurísticas.

Los métodos heurísticos se caracterizan por tener un enfoque específico del problema, buscando una aproximación a la solución óptima global del problema (Lindfield & Penny, 2019). Los métodos metaheurísticos son también métodos heurísticos pero que utilizan un proceso independiente del problema. Esto permite que puedan ser aplicados en distintos tipos de problemas. Se caracterizan también por ser del tipo estocásticos y se suelen inspirar en procesos físicos como la gravedad; y también se inspiran en procesos biológicos como la genética.

De acuerdo a (Gebre et al., 2021), los métodos heurísticos más recurrentes en la literatura para resolver problemas relacionados a la distribución de agua (no necesariamente enfocados en un sistema de río con reservorios como es el caso de la cuenca del río Machángara) son los algoritmos evolutivos como los algoritmos genéticos, NGA II, entre otros. También destacan los algoritmos híbridos y la combinación de algoritmos. A continuación se describen brevemente dos de los algoritmos heurísticos más utilizados en problemas relacionados al manejo y administración del agua de acuerdo a (Gebre et al., 2021). En la sección 3.2 se describe la revisión de literatura realizada sobre los algoritmos heurísticos y metaheurísticos usados en el problema de distribución de agua enfocada en sistemas de ríos con reservorios similares a la cuenca del río Machángara.

2.2.2.1. Algoritmos Genéticos.

Los algoritmos genéticos han sido los algoritmos evolutivos más comúnmente aplicados dentro de la literatura sobre planificación y gestión de recursos hídricos (Gebre et al., 2021; Nicklow, Reed, Savic, Dessalegne, Harrell, Chan Hilton, et al., 2010). Se inspiran en la genética y se caracterizan por los siguientes elementos:

- a. Generación de una población inicial aleatoria, que contienen soluciones potenciales y se identifica a cada una de ellas como un cromosoma.
- b. Cálculo de la función objetivo o una métrica de aptitud para cada cromosoma que permita determinar si sobrevive o no al siguiente paso.

- c. Clasificación cromosómica y selección de las soluciones candidatas (Lindfield & Penny, 2019) que entraran al proceso de apareamiento. De este modo la información de dos o más soluciones padres se combina para generar descendientes.
- d. Mutación de los descendientes para asegurar que exista la diversidad y evitar convergencia de los óptimos locales.

Existen diversos métodos desarrollados para cada uno de los elementos descritos anteriormente. Cabe mencionar que ciertos métodos son recomendados para el área de la asignación del agua (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan Hilton, et al., 2010). Por ejemplo, el proceso de selección de los padres con el método de la rueda de la ruleta no es recomendado en este campo de estudio; ya que puede provocar una convergencia temprana o producen probabilidades de selección casi idénticas que hacen que la búsqueda se desvíe aleatoriamente o se detenga. Mientras que la selección de Boltzmann se ha utilizado con éxito en una variedad de aplicaciones de recursos hídricos. En la Fig. 3 se puede observar un framework general de los algoritmos genéticos extraído de (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan Hilton, et al., 2010).

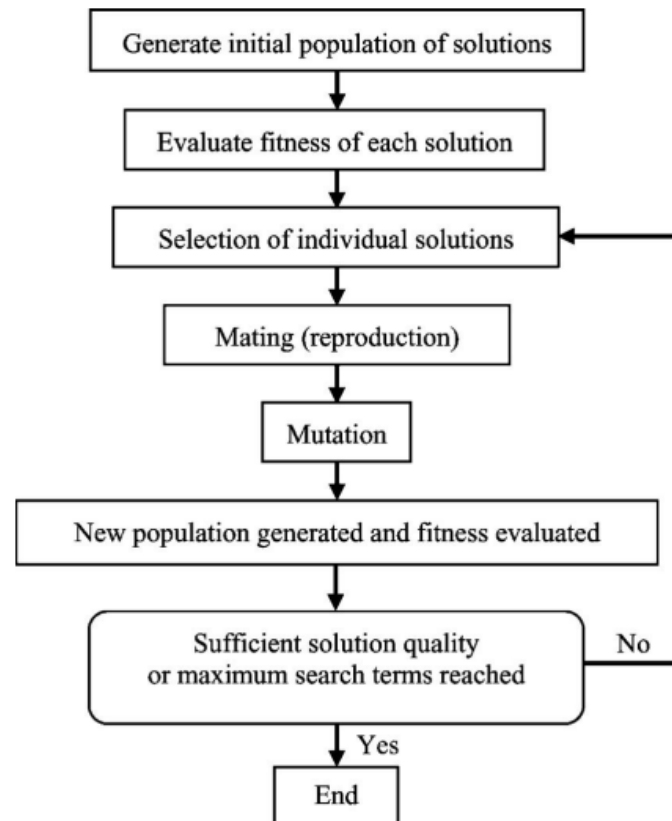


Fig. 3. Framework general de los algoritmos genéticos descrito en (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan Hilton, et al., 2010)

2.2.2.2. NSGA II (Non-dominated sorting genetic algorithm II).

Este algoritmo fue propuesto por (Deb et al., 2002), y es resultado de una mejora del algoritmo genético, siendo NSGA II también usado ampliamente en los problemas de gestión de recursos hídricos (Uen et al., 2018). Sus operadores consisten en los de reproducción, apareamiento y mutación; que son operadores de los algoritmos genéticos también. Pero, se agrega una clasificación no dominada y la clasificación por distancia de hacinamiento.

Este algoritmo realiza una búsqueda de generaciones de padres e hijos, y no retienen únicamente las buenas soluciones de los padres, sino que también aumenta la diversidad en las soluciones. El operador de clasificación no dominado mejora la eficiencia de búsqueda con la estrategia de élite, que es también recomendado dentro del problema de manejo de recursos hídricos (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan Hilton, et al., 2010). Los resultados que NSGA II obtiene suelen formar por lo general el sistema de soluciones del Frente de Pareto, ofreciendo así una diversidad de estrategia óptimas para la solución del problema.

3. Estado del arte.

En términos generales, la diversidad de algoritmos heurísticos y metaheurísticos disponibles para resolver problemas complejos, así como la importancia del problema de distribución del agua, abre un gran abanico de estudios disponibles. Para esta tesis se menciona brevemente los trabajos relacionados y se da un énfasis mayor a una revisión de literatura que tiene como objetivo principal determinar qué algoritmos heurísticos o metaheurísticos son aplicados y han tenido buenos resultados en problemas de optimización de la distribución del agua en sistemas de ríos con reservorios o sistemas de aguas parecidos.

3.1. Trabajos relacionados

Como ya se mencionado, el agua puede estar representado por el WEF-Nexus (nexo agua-energía-alimentos), y de acuerdo a (Yang et al., 2018), el diseño óptimo de un sistema de distribución de agua que cumpla con este nexo se ha convertido en un tema de investigación urgente, por lo que existen estudios centrados en este tema general, pero con objetivos variados y casos de usos diferentes. Esto provoca que cada estudio encuentre una forma única de resolver su problema de optimización debido a lo específico que es el problema; o pueden probar que un método novedoso puede resolver algunos de los problemas generales disponibles para probar la validez de un algoritmo.

El problema de la distribución de agua en la cuenca de un río con reservorios permite la optimización para satisfacer las demandas de distintos nodos que buscan cumplir con el WEF-Nexus. Una forma de representar el sistema de distribución de agua es a través de una red de nodos y arcos. La optimización de dicha red se conoce como Network Flow Optimization (NFO) (Haro et al., 2012). En (Veintimilla-Reyes et al., 2019), el autor utilizó un modelo de programación lineal sobre NFO (NFO-LP) para la optimización de la distribución de agua en la cuenca del río Machángara, considerando también los reservorios. Luego, dentro del mismo estudio, el autor utiliza una extensión del modelo NFO-LP para transformarlo en un modelo de programación lineal mixto de optimización del flujo en una red (NFO-MILP). Esta extensión permite incorporar variables de decisión binarias en la función objetivo para indicar la selección (o no) de un nodo como un reservorio candidato. Cabe mencionar que los sistemas de programación matemática, como NFO-LP, requieren altos consumos computacionales dependiendo de la dimensión de la red.

La optimización de la distribución de agua puede ser abordada con otros métodos (Gebre et al., 2021). (Labadie, 2004) menciona entre los métodos más comunes a los modelos de programación lineal, no lineal, dinámica-discreta y heurística. A diferencia de la programación lineal que busca entregar una solución exacta, que puede terminar en un óptimo local antes que un global (Lindfield & Penny, 2019), los métodos heurísticos pueden encontrar una aproximación a la solución óptima global. Shourian & Mousavi, (2017) aplicaron métodos heurísticos (particle swarm optimization) en combinación con el modelo NFO. Sus objetivos eran buscar los valores óptimos de las capacidades de los reservorios y sus prioridades de almacenamiento, así como encontrar valores óptimos para las asignaciones de agua en los canales y reservorios de la cuenca estudiada. Yang et al., (2018) se enfoca en optimizar los principios de equidad y efectividad de la distribución del agua a través de un algoritmo de búsqueda rápida de armonía multiobjetivo (multiobjective fast harmony search algorithm). También se destaca el uso de algoritmos evolutivos y genéticos para este tipo de optimización (da Conceição Cunha & Ribeiro, 2004; Jamshidpey & Shourian, 2021; Joycee, 2015; Mora Meliá, 2012; Rey et al., s. f.) pero en estos casos se enfocan en la optimización de redes de tuberías para la distribución del agua.

En la siguiente sección se realiza una revisión de literatura que aborda con mayor profundidad los trabajos relacionados con mayor profundidad al problema planteado para esta tesis, pero el trabajo que mayor relación tiene y antecesor de este estudio es el realizado en (Veintimilla-Reyes et al., 2019).

3.2. Revisión de literatura de los métodos heurísticos para resolver este tipo de problemas.

3.2.1. Introducción.

En esta sección se presenta la revisión sistemática de literatura llevada a cabo para encontrar que algoritmos heurísticos o metaheurísticos han sido aplicados en problemas de distribución de agua en un sistema de río con reservorios. El resto de la sección se distribuye de la siguiente manera: en la sección 3.2.2 se indica la metodología utilizada para la revisión de los métodos heurísticos, en la sección 3.2.3 se presentan los resultados y la discusión sobre los mismos, finalmente en la sección 3.2.4 se da una conclusión de esta revisión sistemática de literatura.

3.2.2. Materiales y Métodos.

El diseño de revisión sistemática respondió al propósito de recolectar, seleccionar, evaluar y resumir la evidencia encontrada respecto a métodos heurísticos o meta-heurísticos que han sido

aplicados en problemas de optimización de distribución de agua en un sistema de río con reservorios. Para realizar esta revisión sistemática se aplicó la metodología Fink, la cual consta de las siguientes tareas: 1) Seleccionar las preguntas de investigación, 2) Seleccionar bases de datos bibliográficas y sitios web, 3) Elegir términos de búsqueda, 4) Aplicar revisión práctica, 5) Aplicar revisión de calidad metodológica, 6) Hacer la revisión y 7) Sintetizar los resultados (Fink, 2013).

La revisión sistemática se inició con la selección de las preguntas de investigación. Se estableció que la pregunta principal a responder es: ¿Qué métodos heurísticos o meta-heurísticos se han aplicado en la optimización de problemas de distribución de agua en un sistema de río con reservorios? Posteriormente, se definieron las sub preguntas de investigación, cuyo objetivo es obtener información para delimitar el campo de investigación estudiado. Estas preguntas son: 1) ¿Cuáles fueron los objetivos de la optimización de los problemas de distribución de agua en la cuenca del río? 2) ¿Qué herramientas o solucionadores se utilizan para resolver modelos de optimización? 3) ¿Qué partes están involucradas en el proceso de optimización? y 4) ¿Qué indicadores se utilizan para analizar o validar los resultados del modelo de optimización?

Una vez definidas las preguntas de investigación, es necesario seleccionar las bases de datos bibliográficas y los sitios web. Se selecciona Google Scholar porque este motor de búsqueda permite incorporar cadenas de búsqueda personalizadas con operadores 'y' y 'o'; y también permite el acceso a artículos publicados en diversas revistas y bases de datos. Además, Google Scholar es una base de datos común de fácil acceso entre los investigadores. Para buscar los artículos primarios para referenciar esta revisión, se definió una cadena de búsqueda, la cual se detalla en la Tabla 2. La cadena estuvo compuesta por los términos relevantes y conectores lógicos, lo que permitió combinar diferentes términos y establecer relaciones lógicas entre ellos. Los artículos resultantes de la búsqueda son considerados como referencia para la revisión sistemática si cumplen con los criterios indicados en la *Tabla 2*.

Tabla 2. Criterios de búsqueda para la revisión sistemática de la literatura

Cadena de búsqueda	("heuristic" or "meta heuristic") and ("optimization" and modeling or simulation) and ("water allocation") and (river "basin" or "river" or river with "reservoirs")
Fechas	2010-2022

Lenguaje	Inglés y español
Criterios de inclusión	Criterios de exclusión
Estudios que aplican métodos heurísticos o metaheurísticos para optimizar o simular la distribución de agua sobre una cuenca fluvial o sistemas de agua similares. Puede o no contener reservorios.	Estudios enfocados exclusivamente a la gestión de reservorios, ya que el objetivo es todo el sistema de río y no sólo el reservorio.
Revisiones de literatura que incluyan métodos heurísticos o meta-heurísticos aplicados en problemas de optimización y/o simulación en un sistema de río o similar.	Distribución de agua en áreas de cultivo que no consideran al sistema de río como parte del problema.
Artículos que incluyen heurísticas y metaheurísticas en proyectos hidrológicos similares a la distribución de agua en un sistema de río.	Distribución de agua por tuberías y asignación de aguas subterráneas.

Con la cadena de búsqueda estructurada, se recuperaron 178 artículos. De los resultados obtenidos tras aplicar los primeros filtros, se seleccionaron los artículos que cumplían con los criterios de inclusión luego de revisar títulos, resúmenes y palabras clave. Una vez aplicados todos los filtros, se realizó una revisión manual de los artículos para determinar las fuentes secundarias. Se leyeron un total de 43 artículos para determinar su fiabilidad. A continuación, los artículos fueron seleccionados en base al uso del método de optimización y la explicación de cómo utilizarlo, las funciones objetivo, las restricciones y los resultados obtenidos con su modelo propuesto. Además, los artículos también debían cumplir con los criterios de inclusión detallados en la *Tabla 2*. A través de esta selección se obtuvieron un total de 16 artículos para la revisión sistemática. Cabe mencionar que también se encontraron artículos de revisión de literatura relacionados con este tema, los cuales brindan una visión general de los métodos heurísticos, de los cuales se destacan 6 revisiones de literatura.

3.2.3. Resultados y Discusión.

Esta sección presenta los principales hallazgos de esta revisión sistemática y resume los resultados obtenidos después de filtrar los artículos. Teniendo en cuenta los criterios de inclusión mencionados en la sección anterior, los artículos útiles para esta revisión de literatura fueron clasificados y resumidos en la *Tabla 2*.

3.2.3.1. Preguntas de investigación.

3.2.3.1.1. Pregunta de investigación principal.

La pregunta principal de investigación de esta revisión de literatura es: ¿Qué métodos heurísticos o meta-heurísticos se han aplicado en problemas de optimización de distribución de agua en un sistema de río con reservorios? Para responder a esta pregunta, se debe mencionar la clasificación de algoritmos heurísticos encontrada en (Kumar & Yadav, 2022), la cual se puede ver en la Fig. 4. Esta clasificación más el histograma (ver Fig. 5) permite observar que hay un énfasis en los algoritmos basados en poblaciones, donde los algoritmos del tipo "inteligencia de enjambre" tienen una mayor presencia con un total de 13 ítems. Dentro de estos artículos se aplican algoritmos específicos como PSO, ACO, HS, etc.

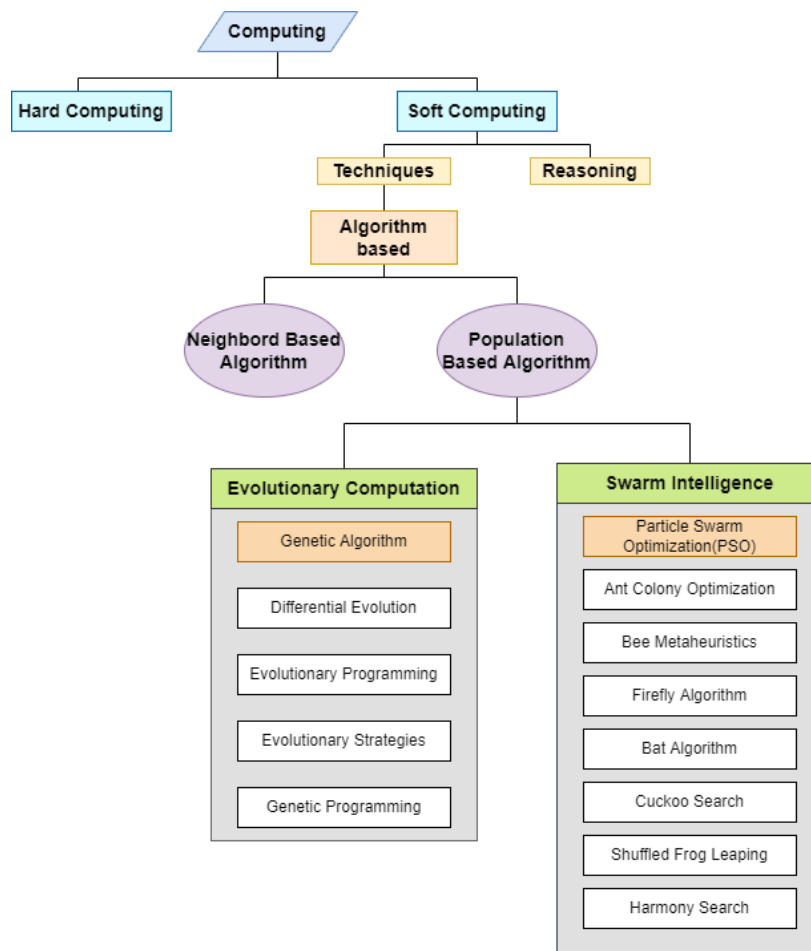


Fig. 4. Parte de la clasificación de los algoritmos heurísticos por (Kumar & Yadav, 2022)

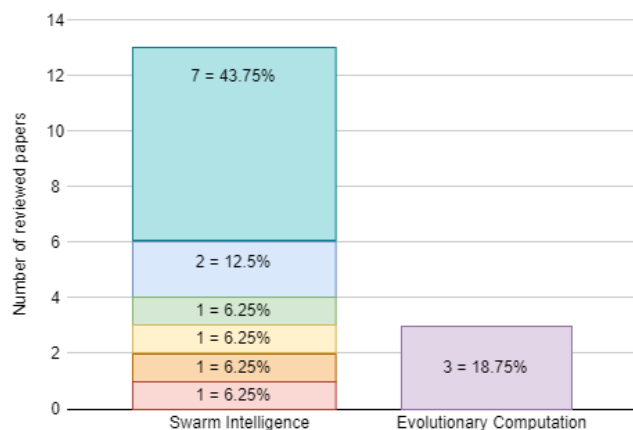



Fig. 5. Histograma de los métodos heurísticos utilizados en los artículos revisados.

3.2.3.1.2. Sub preguntas de investigación.

En la sub pregunta de investigación 1: ¿Cuáles fueron los objetivos de los problemas de optimización de la distribución de agua en la cuenca del río? Los artículos revisados tenían diferentes objetivos, sin embargo, la diferencia es que ciertos artículos tenían el objetivo de probar o validar un algoritmo híbrido novedoso, mientras que otros estudios tenían el objetivo de resolver el problema de optimización sin darle prioridad al algoritmo. Otro de los objetivos encontrados es el enfoque en los reservorios, pero cabe recalcar que el estudio no se centró solo en los reservorios, sin embargo, sí presenta mayor interés en estos que en el resto de variables a considerar dentro del problema. Por ejemplo, (Shourian & Mousavi, 2017) tiene como objetivo encontrar valores óptimos para una gran cantidad de descargas de agua en los enlaces de la red (ríos y canales) y nodos (embalses y demandas) al tiempo que busca los valores óptimos de las capacidades de los reservorios y sus prioridades de almacenamiento.

Otro objetivo a destacar es el énfasis en los aspectos sociales. Este es el caso de (Habibi Davijani et al., 2016), que propone un modelo socioeconómico con dos objetivos. El primero es maximizar la rentabilidad económica y maximizar el empleo mediante la asignación óptima de agua a los sectores agrícola e industrial con el objetivo de crear empleo en estos sectores. En el segundo objetivo se considera la influencia de la distribución del agua en el bienestar social. Otros estudios (Babamiri et al., 2022; Habibi Davijani et al., 2016; Kazemi et al., 2020; Shourian & Mousavi, 2017; Yang et al., 2018) también tienen un enfoque social al considerar la asignación de agua para satisfacer la demanda de agua de la población sin considerar si hay beneficio económico o no.

También se considera un objetivo importante buscar el equilibrio ecológico en la asignación del agua. Este es el caso de los estudios (Farrokhzadeh et al., 2020; Habibi Davijani et al., 2016; Kazemi et al., 2020; Qu & Lou, 2013; Szemis et al., 2013). Por ejemplo, en (Liu et al., 2012) el objetivo se resume en minimizar la escasez de agua y la cantidad de agua contaminada, pero también busca maximizar los intereses económicos incluyendo la generación de energía hidroeléctrica. Los otros artículos también presentaron varios objetivos, sin embargo, consideraron importante el equilibrio ecológico.

Varios artículos también mencionan la importancia de las áreas agrícolas (Ashrafi et al., 2017; Habibi Davijani et al., 2016; Jamshid Mousavi et al., 2017; Liu et al., 2012; Qu & Lou, 2013;

Shourian & Mousavi, 2017; Yang et al., 2018). Por ejemplo, en (Jamshidpey & Shourian, 2021) hay un enfoque en la asignación de agua para riego que es compatible con las condiciones del cambio climático en la llanura de Borkhar en Irán.

En la sub pregunta de investigación 2: ¿Qué herramientas o solucionadores se utilizan para resolver modelos de optimización? Algunos de los artículos decidieron incorporar los métodos heurísticos con modelos de simulación como WEAP (software de planificación y evaluación del agua) (Qu & Lou, 2013) o MODSIM (software basado en la programación de flujo de red) (Jamshid Mousavi et al., 2017; Jamshidpey & Shourian, 2021). Tanto WEAP como MODSIM son modelos hidrológicos basados en ecuaciones diferenciales. La ejecución de algoritmos heurísticos se puede realizar con MATLAB (Yang et al., 2018) o programando con lenguajes como Python. Los artículos no especifican en detalle qué herramientas de software se utilizaron para la programación y/o ejecución de los algoritmos, solo presentan los resultados.

En la sub pregunta de investigación 3: ¿Qué partes están involucradas en el proceso de optimización? Los pasos llevados a cabo en (Habibi Davijani et al., 2016) engloban los pasos a seguir en un estudio a partir de la recogida de datos. Además, considera la distribución del agua en el ámbito agrícola, industrial y de consumo humano, con la incorporación de criterios sociales y económicos. Las partes involucradas se resumen en: Toma de datos, elaboración del modelo de optimización e implementación del modelo. En la recogida de datos se contemplan las fuentes de agua, las estadísticas necesarias (económicas, poblacionales, etc.) y los datos existentes sobre los recursos hídricos. Al elaborar el modelo de optimización se deben definir las variables de decisión, objetivos y restricciones. Para la parte de implementación se incluye la ejecución del modelo de optimización, así como el análisis de los resultados en base a lo indicado en los objetivos del estudio.

En la sub pregunta de investigación 4: ¿Qué indicadores se utilizan para analizar o validar los resultados del modelo de optimización? Se pueden observar dos formas generales de validación de resultados. La primera forma es comparar el modelo meta-heurístico desarrollado con otro modelo heurístico (Asgari et al., 2019; Fang et al., 2018; Qu & Lou, 2013; Yang et al., 2018). La segunda forma es analizar el frente de Pareto y considerar las diferentes compensaciones entre los objetivos (Babamiri et al., 2022; Farrokhzadeh et al., 2020; Jamshid Mousavi et al., 2017; Kazemi et al., 2020; Liu et al., 2012; Yang et al., 2018). También se hacen comparaciones con la situación actual, como es el caso de (Habibi Davijani et al., 2016), donde el algoritmo PSO arrojó resultados que produjeron un crecimiento del 38% en beneficios económicos y rentabilidad en el

sector agropecuario, un crecimiento del 86% en el sector industrial y un crecimiento económico general del 54% en relación con la condición actual.

3.2.3.2. Análisis y discusión.

Los resultados de la revisión sistemática han revelado las principales características de dos familias de métodos de optimización recurrentes, como son los algoritmos basados en evolución y los algoritmos basados en inteligencia poblacional. Además, se destaca que estos métodos podrían funcionar solos o combinarse con otros procesos de optimización, técnicas de simulación o metamodelos para mejorar el rendimiento del modelo.

Además de minimizar la escasez de agua en áreas de demanda para consumo humano, también existe interés en distribuir agua en áreas industriales y agrícolas. Estas áreas no solo producen bienes como alimentos, sino que también pueden ser generadores de empleo y producir beneficios económicos para la región. Otro interés es cómo la distribución de agua puede afectar el medio ambiente y también cómo cumplir con el bienestar ecológico de la región. El área que más aparece en la bibliografía revisada es la parte socioeconómica. Esta área es grande y abarca aspectos sociales como el derecho al acceso al agua potable, así como la reducción de costos (costos en reservorios, producción agrícola que dará más ingresos, producción industrial que traerá ingresos económicos y también fuente de trabajo, etc.). Estas áreas pueden presentar conflictos. Por ejemplo, para aumentar el beneficio económico en un área como la industrial, se puede restringir la cantidad de agua en el área agrícola.

Los artículos encontrados para esta revisión de literatura tienen enfoques de simulación-optimización, optimización multiobjetivo, mejoras de algoritmos clásicos o construcción de algoritmos híbridos. En este contexto de estudio, los modelos de simulación-optimización se refieren al proceso de incorporar un algoritmo meta-heurístico en un modelo de simulación. Por ejemplo, en (Jamshid Mousavi et al., 2017) se utiliza este enfoque. WEAP es el modelo de simulación, que consiste en un software de evaluación y planificación del agua que optimiza las decisiones de distribución de agua utilizando programas lineales (Farrokhzadeh et al., 2020). Pero los problemas de optimización de distribución de agua suelen ser no lineales a gran escala, por lo que es posible integrar este sistema WEAP con el algoritmo metaheurístico para optimizar el problema. De esta forma, el marco general consiste en definir las funciones objetivo, ejecutar el algoritmo metaheurístico y determinar si se cumplió el objetivo utilizando la simulación (WEAP) para evaluar las funciones objetivo con los valores encontrados por el algoritmo metaheurístico.

Otro término a mencionar es la optimización multiobjetivo. Para entender el concepto, es necesario enfatizar que existen diferentes enfoques para el manejo de restricciones en algoritmos evolutivos (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan-Hilton, et al., 2010), que incluyen: funciones de penalización, operadores de reparación o búsqueda local, operadores modificados de coincidencia/mutación que preservan restricciones y multi- formulaciones objetivas donde las restricciones se reformulan como objetivos. La optimización multiobjetivo busca aproximar las compensaciones óptimas de Pareto entre objetivos en conflicto. Estas compensaciones se componen del conjunto de soluciones que son mejores que todas las demás soluciones en al menos un objetivo y se denominan soluciones óptimas de Pareto o no dominadas (Pareto, 1896). Una fortaleza de la optimización multiobjetivo es su capacidad para aproximarse rápidamente a la verdadera superficie de Pareto, incluso si no está cuantificada con exactitud (Nicklow, Reed, Savic, Dessalegne, Harrell, Chan-Hilton, et al., 2010).

Comenzando por el clásico algoritmo PSO, que se basa en el comportamiento social de bandadas de pájaros para buscar a través de espacios de dimensiones multidimensionales, ha sido ampliamente utilizado en la optimización de sistemas de recursos hídricos (Jamshid Mousavi et al., 2017) y también es uno de los algoritmos más recurrentes dentro de esta revisión sistemática. Este algoritmo se ha aplicado junto con el enfoque multiobjetivo y de simulación-optimización. En (Jamshid Mousavi et al., 2017) se utilizan ambos enfoques generando un modelo MOPSO-WEAP para analizar la efectividad de un proyecto de distribución de agua. En este caso, WEAP es el modelo de simulación, mientras que MOPSO es el objetivo heurístico. Se definieron dos funciones objetivas que eran minimizar los tamaños de las infraestructuras del proyecto y maximizar la confiabilidad del suministro de agua a las tierras agrícolas. Los resultados de aplicar optimización-simulación con PSO (MOPSO-WEAP) indicaron que el proyecto puede cumplir con estos objetivos.

Otro estudio que utiliza la técnica de simulación-optimización es el realizado en (Jamshidpey & Shourian, 2021), que en este caso utiliza MODSIM (basado en programación de flujo de red) como modelo de simulación y se combina con el algoritmo de optimización lobo gris (GWO – Gray Wolf Optimization) para obtener las cantidades óptimas de riego y áreas de cultivo en la llanura bajo dos condiciones: status quo, y con caudales afectados por el cambio climático. La cuenca de estudio es la cuenca de Zayandehroud, primero se elabora su red en el modelo MODSIM y se ingresa la información relativa a cada nodo en base a los datos medidos en las

estaciones meteorológicas e hidrométricas. La función objetivo del modelo es maximizar las ganancias de la producción de cultivos y planificar la distribución óptima del agua.

Continuando con la línea de estudios donde se aplica simulación y optimización, se encuentra la realizada en (Mirfenderesgi & Mousavi, 2016). Este estudio afirma que el sistema de simulación evitaría tener variables, funciones, relaciones, entre otros, y además lograría un sistema continuo. Sin embargo, la meta heurística debe evaluar la función objetivo en esta simulación, que se vuelve computacionalmente intensiva. Para abordar este problema, proponen el metamodelo, que se utiliza para producir sustitutos computacionalmente eficientes para los modelos de alta fidelidad. Las más comunes son ANN (redes neuronales artificiales), SVM (máquinas de vectores de soporte), kriging y funciones polinómicas, que se evalúan en un problema de asignación de agua basado en la optimización sustituta en la cuenca del río Atrak en Irán. El objetivo del estudio fue comparar el rendimiento de los cuatro meta-modelos mencionados anteriormente. El modelo de simulación utilizado es MODSIM, que es una herramienta que permite analizar el funcionamiento de los sistemas fluviales como redes de nodos y segmentos. Mientras que el objetivo heurístico aplicado es la optimización del enjambre de partículas (PSO). Como conclusiones determinan que los metamodelos ANN y SVM funcionan mejor que otros al ahorrar el costo de evaluar las funciones objetivo sobre el modelo original.

Otro enfoque utilizado es la mejora del algoritmo que se puede ampliar para reducir el uso de hardware, menos tiempo de computadora, mayor convergencia, etc. El estudio realizado por (Yan et al., 2018) utiliza un algoritmo metaheurístico basado en PSO, el Algoritmo de Optimización de Ballena (WOA). Este algoritmo tiene algunos inconvenientes, como una precisión de convergencia y una tasa de convergencia relativamente bajas cuando se aplica a problemas de optimización complejos. Los autores realizaron una mejora con el mapeo logístico para inicializar la ubicación del enjambre y mejorar la calidad de la ubicación del enjambre de inicialización. El algoritmo fue nombrado como AWOA.

Además, la ponderación inercial se utiliza para fortalecer las capacidades de búsqueda local. En comparación con el algoritmo WOA y PSO, el AWOA muestra tasas de convergencia y precisión sustancialmente mejoradas. El objetivo de este estudio es probar la mejora frente a los algoritmos WOA y PSO tradicionales para la resolución de asignación de recursos hídricos con objetivos múltiples. En este caso, los resultados de AWOA indican que existe una mayor precisión de convergencia.

También se presentan algoritmos híbridos, como es el caso de (Asgari et al., 2019), que integra el algoritmo de optimización de malezas (WOA) y PSO, denominándose a este híbrido WOAPSO. Este algoritmo se valida en dos casos de estudio, el primer caso de estudio consiste en un ejemplo de una cuenca fluvial con 10 embalses, mientras que el segundo es un problema de optimización hidroeléctrica de tres embalses en la cuenca del río Karoon en Irán, que maximiza el índice de eficiencia de producción de energía hidroeléctrica. Los resultados se comparan con los obtenidos por los algoritmos tradicionales de programación lineal (LP), programación no lineal (NLP), WOA (en este caso es el algoritmo de malezas - Weed Optimization Algorithm) y PSO; donde WOAPSO demostró ser más confiable para resolver sistemas complejos de múltiples embalses en el contexto de la gestión integrada de cuencas fluviales que los algoritmos de optimización clásicos.

El siguiente algoritmo con mayor presencia es el algoritmo genético y sus extensiones. Por ejemplo, en (Farrokhzadeh et al., 2020) un algoritmo genético de optimización multiobjetivo (MOGA) está vinculado al software WEAP para optimizar las decisiones de asignación de agua durante varios años. La región de estudio es Sistán, la cual se caracteriza por ser una zona árida, donde las variables de diseño del problema consisten en el área cultivada, el patrón de cultivo y los requerimientos de afluencia al humedal durante 30 años. El objetivo es maximizar el beneficio económico neto a largo plazo y maximizar el flujo de agua hacia el humedal. Estos objetivos son incompatibles entre sí, pero el enfoque adoptado en este estudio permite obtener resultados que se analizan comparando escenarios puramente económicos versus escenarios multiobjetivo en el frente de Pareto. Los autores también brindan una descripción de las compensaciones en estos escenarios para ayudar en el proceso de decisión de las partes interesadas en los recursos hídricos.

También está el uso de colonias de hormigas (ACO) como algoritmo de inspiración, que es un algoritmo de optimización combinatorio discreto basado en el comportamiento colectivo de las hormigas en su búsqueda de alimento. La revisión de la literatura realizada por (Afshar et al., 2015) menciona que existen diferentes versiones de ACO que han demostrado ser flexibles y poderosas para resolver una serie de problemas de recursos hídricos espacial y temporalmente complejos en dominios discretos y continuos con objetivos únicos y/o múltiples. Uno de los artículos a destacar dentro de esta revisión es (Szemis et al., 2013), que presenta un marco de optimización de objetivos múltiples con ACO para desarrollar compensaciones óptimas entre la asignación de agua y el beneficio ecológico en un tramo del río Murray en el sur de Australia. Los

resultados indican que se puede obtener un beneficio ecológico adicional limitado a medida que aumenta la asignación, relajando las restricciones de flujo del sistema. Además, el uso de reguladores puede aumentar los beneficios ecológicos al usar menos agua.

Como se indica en la respuesta a la pregunta 4 de esta revisión sistemática, la mayoría de los autores de los artículos revisados incluyen un análisis de los resultados. El análisis puede ser una comparación entre métodos de optimización o un análisis de frente de Pareto. También se considera si los algoritmos pueden converger a una respuesta y el tiempo necesario. Otro análisis recurrente es el beneficio obtenido al optimizar la asignación de agua y cuánta agua se asignó a cada nodo de demanda. Aunque no se mencionan en detalle todos los artículos encontrados, se puede observar que existe una fuerte inclinación hacia los métodos multiobjetivo y la simulación-optimización. También se destaca la mejora de algoritmos clásicos o una mezcla de algoritmos para obtener nuevas heurísticas. Los problemas de optimización de la gestión del recurso hídrico en general son problemas complejos a resolver que dependen del número de variables a considerar, los objetivos, las restricciones y el enfoque deseado. Por lo tanto, utilizar métodos mejorados de metaheurísticas, multiobjetivo y simulación-optimización resulta ser la mejor opción para estos problemas. Otro aspecto a tener en cuenta es la fuerte presencia de los algoritmos basados en PSO seguidos de los Algoritmos Genéticos, ya que ambos ofrecen una serie de variantes, así como la flexibilidad para incorporarlo a sistemas de decisión como WEAP.

3.2.4. Conclusiones

Aunque no se mencionan en detalle todos los artículos encontrados, se puede observar que existe una fuerte inclinación hacia los métodos multiobjetivo y la simulación-optimización. También se destaca la mejora de los algoritmos clásicos o el uso de algoritmos híbridos. Los problemas de optimización de la gestión del recurso hídrico en general son problemas complejos a resolver que dependen del número de variables a considerar, los objetivos, las restricciones y el enfoque deseado. Por lo tanto, utilizar métodos mejorados de metaheurística, multiobjetivo y simulación-optimización resulta ser la mejor opción para estos problemas. Para responder a la pregunta principal de investigación sobre qué métodos heurísticos o metaheurísticos se han aplicado en problemas de optimización de distribución de agua en un sistema de río con reservorios, se ha encontrado que cada autor decidió utilizar el método que mejor se adaptaba a sus necesidades. Sin embargo, es necesario mencionar que existe una fuerte presencia de algoritmos basados en PSO, ya que ofrece una serie de variantes, así como la flexibilidad para incorporarlo con sistemas de decisión como WEAP.

PSO, los algoritmos genéticos y los demás algoritmos mencionados en esta revisión tienen sus limitaciones. En el estudio realizado en (Kumar & Yadav, 2022) se resumen las ventajas y desventajas de algunos algoritmos meta-heurísticos en problemas de recursos hídricos, incluyendo PSO. Para la familia de algoritmos de PSO, (Kumar & Yadav, 2022) menciona que la ventaja de este tipo de algoritmos es que son simples de codificar y proporcionan una rápida convergencia, lo que también implica un bajo costo computacional. Como desventaja, es necesario ajustar parámetros como el peso inercial, parámetros sociales y cognitivos. Sin embargo, si los parámetros se configuran correctamente, el algoritmo puede lograr una solución global.

Esta revisión sistemática pretende facilitar la toma de decisiones sobre modelos de optimización que puedan ser utilizados en problemas de optimización de asignación de agua en un sistema fluvial con embalses, considerando la efectividad y eficiencia que estos tuvieron al ser aplicados en escenarios reales.

4. Materiales y Métodos.

4.1. Los datos hidrológicos de la cuenca del río Machángara.

El caso de estudio planteado de la cuenca del río Machángara no tenía disponible series de tiempo de descarga, es por esta razón que en (Veintimilla-Reyes et al., 2019) detallan como se puede ejecutar un modelo hidrológico como SWAT (Texas A&M University, 2018) basado en información geográfica para generar la información faltante. Para ejecutarse, SWAT debe contar con varios conjuntos de datos de entrada, como un modelo de elevación digital (DEM), un mapa de suelos, un mapa de cobertura terrestre e información meteorológica. Este modelo es capaz de generar series temporales de caudales, series temporales de precipitaciones, entre otros, para las localidades de interés de la región de estudio.

En (Veintimilla-Reyes et al., 2019) se indica que no había datos reales disponibles para el área de estudio, por lo que se aplicó el modelo ArcSWAT para obtener la serie de tiempo de descarga requerida utilizando los valores de parámetros predeterminados del modelo. La información meteorológica utilizada se obtuvo de “Global Weather Database for SWAT” (Texas A&M University, 2018). Esta información meteorológica se interpoló en función de algunas estaciones meteorológicas ubicadas en el área, en este caso fue con la estación de El Labrado. Los datos precisos de precipitación medidos desde el suelo son la entrada más importante para modelar las descargas de los ríos, pero a menudo no están disponibles en áreas remotas (Roth & Lemann, 2016). (Roth & Lemann, 2016) compararon el conjunto de datos GWD4S (Global Weather Dataset for SWAT) con datos meteorológicos convencionales para el modelado de caudales con SWAT en pequeñas cuencas ubicadas en las tierras altas de Etiopía, y obtuvieron mejoras significativas. Es por esta razón que en (Veintimilla-Reyes et al., 2019) se aplica el mismo método considerando que GWD4S incluye 35 años de datos (1979 – 2014).

Sin embargo, los datos de GWD4S sobreestimaban los valores de precipitación y temperatura, por lo que en (Veintimilla-Reyes et al., 2019) se realizó un re-escalado de los datos, y una vez comparados los RMSD con los datos de El Labrado, se usan estos datos para los modelos matemáticos exactos de LP y MILP. Y son estos datos los que se usan en el modelo heurístico que se propone en este estudio para poder comparar los resultados bajo el mismo contexto.

4.2. Modelamiento hidrológico

Para el modelamiento hidrológico se plantea una optimización de flujo de red o NFO (Network Flow Optimization), que en (Veintimilla-Reyes et al., 2019) se resuelve con los algoritmos matemáticos exactos de LP y luego MILP. En este caso se usa la misma red del caso de uso de la cuenca del río Machángara, pero en este caso se resuelve con el método heurístico que se selecciona en base a la revisión de literatura planteada dentro de este mismo estudio.

La subdivisión de cuencas y configuración de redes fueron generadas por ArcSWAT, como es visible en Fig. 6 donde cada nodo de transferencia se identifica con un código “Tx”, mientras que el código “Rx” se utiliza para los nodos de embalse: R1 es Chanlud, R2 es Labrado, R3 es Saucay y R4 es Saymirin. También se incluye la ubicación de la estación meteorológica virtual “p-27-791” (Texas A&M University, 2018) que fue usada en también en la comparación de los datos de entrada para el re-escalado.

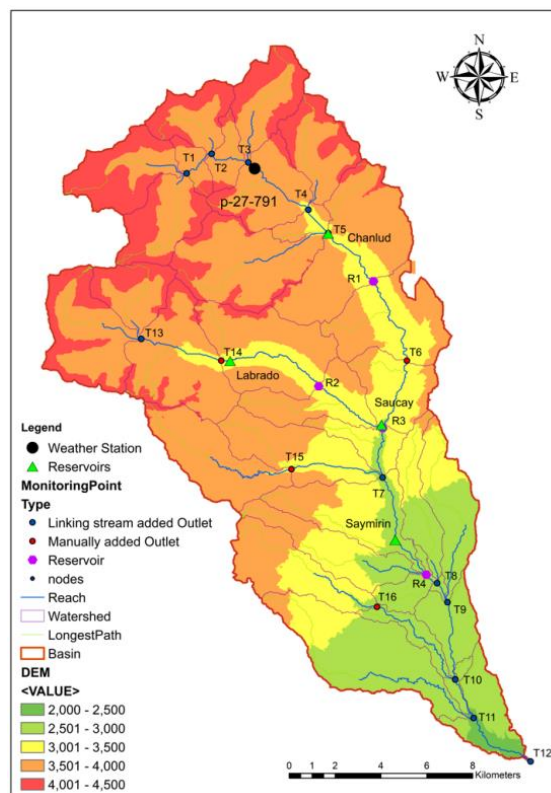


Fig. 6. Configuración de red fluvial para la cuenca Machángara.

La configuración de red resultante del preprocesamiento realizado en (Veintimilla-Reyes et al., 2019) consta de 16 nodos de transferencia (T), 4 nodos de embalse (R) y 19 segmentos de río.

La longitud y el ancho de cada segmento se derivaron de Google Earth, asumiendo una profundidad de 3 m para calcular la sección transversal (FAO, 2017; Google, 2007). Se agregaron también 6 nodos de demanda, donde en la Tabla 3 se detalla el uso que se da del agua en cada nodo de demanda y para el caso de uso planteado se asume que las demandas de agua de los seis nodos son constantes a lo largo del tiempo.

Tabla 3. Agua diaria requerida por los nodos de demanda (Promas, 2022)

Nodo	Uso	Valor(hm³/día)
D1	Planta de energía Saucay	0.620
D2	Sistema de riego Machángara	0.043
D3	Central de Saymirin	0.691
D4	Sistema de agua potable de Tixán	0.121
D5	Sistema de riego Ricaurte	0.026
D6	Función del ecosistema	0.017

Finalmente, en *Fig. 7* se muestra la configuración final de la red con el río principal Machángara y los tres afluentes (Chulco, Chachayacu y Patamarca). El río Chulco se conecta con el río Machángara a través de los embalses R2 y R3. El río Chachayacu da entrada al nodo de transferencia T15 y el tramo correspondiente se conecta al río Machángara a través del nodo de transferencia T7. Finalmente, el río Patamarca da entrada al nodo T16 y se conecta a través del nodo T10 con el río Machángara. Se asume que el agua necesita un paso de tiempo (un paso de tiempo corresponde a un día en este caso de estudio) para fluir de un nodo al siguiente.

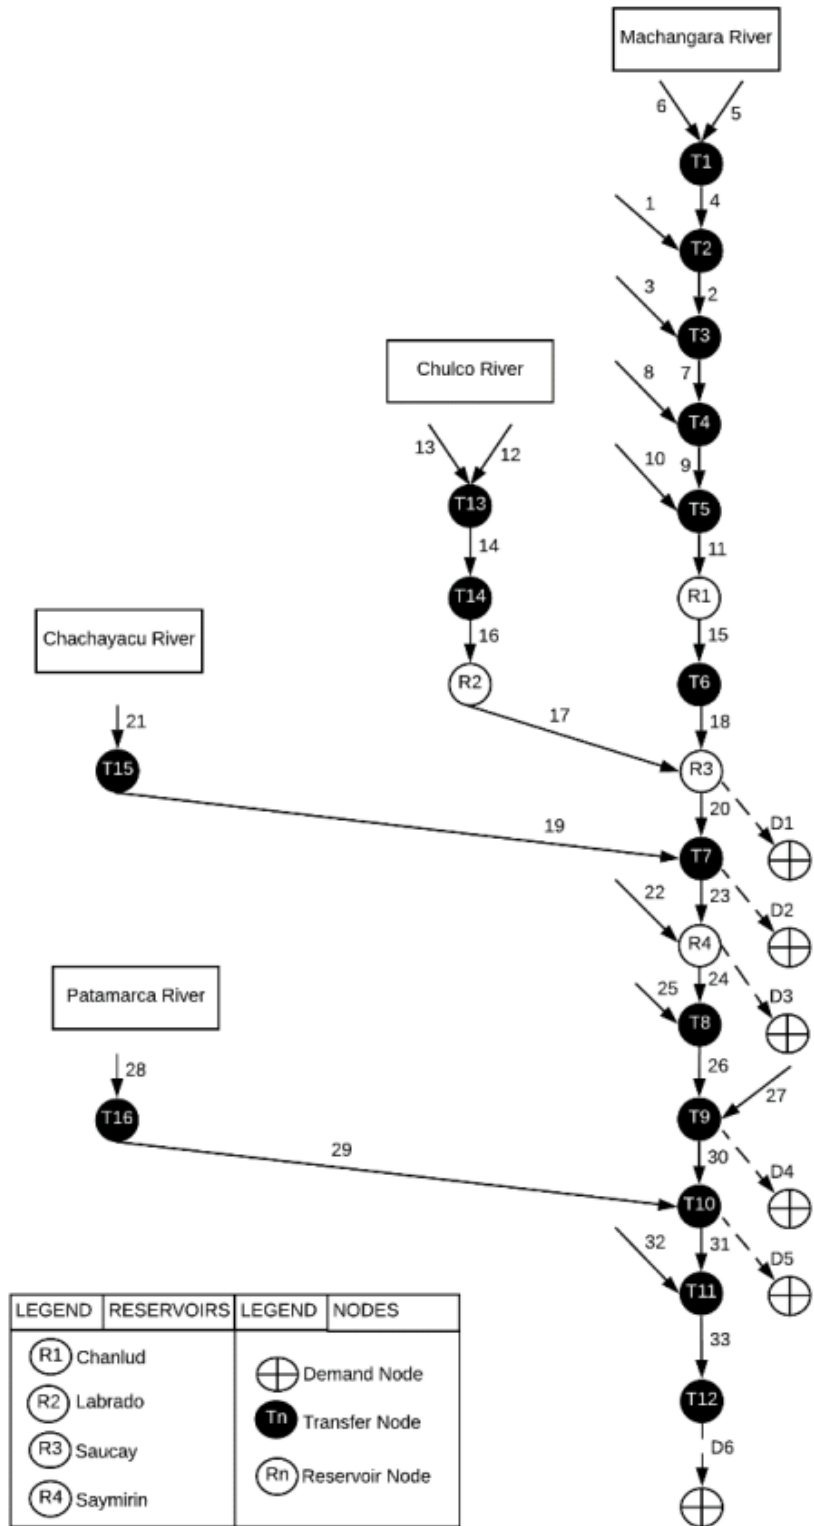


Fig. 7. La configuración final de la red del sistema fluvial Machángara (Veintimilla-Reyes et al., 2019).

4.3. Selección de las variables y restricciones a considerar dentro del modelamiento.

En (Veintimilla-Reyes et al., 2019) se trata a detalle el modelamiento de las funciones matemáticas para la optimización de la distribución del agua en el capítulo 2. En esta sección se presenta lo más importante de dichas funciones, y estas son las funciones que se van a programar para ser resueltas por el método heurístico cuya implementación está sujeta al algoritmo y lenguaje de programación utilizado.

$$\begin{aligned}
 \text{minimize } & \sum_n \sum_d \sum_t (P_n * S_{n,d}^{t-}) \\
 & + \sum_n \sum_d \sum_t (E_n * S_{n,d}^{t+}) + \sum_r \sum_t (U_r * SH_r^{t-}) + \sum_r \sum_t (A_r * OF_r^{t+}) \\
 & + \sum_n \sum_t (W_n * T_{n,n+1}^{t+}) + \sum_n \sum_t (B_n * Q_{n,n+1}^{t-}) + \sum_n \sum_d \sum_t (F_n * MinXD_{n,d}^{t-}) \\
 & + \sum_n \sum_d \sum_t (G_n * MaxXD_{n,d}^{t+})
 \end{aligned}$$

Eq (1) (Veintimilla-Reyes et al., 2019)

En la Eq (1) se presenta la función objetivo a ser minimizada donde:

- El primer término se refiere a las demandas insatisfechas ($S_{n,d}^{t-}$) y sus correspondientes penalizaciones (P_n);
- El segundo término ($S_{n,d}^{t+}$) está relacionado con las penalidades cuando se asigna más agua de la requerida a un nodo de demanda;
- Los términos (SH_r^{t-}) y (OF_r^{t+}) están relacionados con una penalización por no alcanzar el volumen mínimo en y por exceder la capacidad máxima de los embalses respectivamente
- El quinto término ($T_{n,n+1}^{t+}$) está relacionado con la sanción por crecida de un segmento de río;
- El sexto término ($Q_{n,n+1}^{t-}$) se refiere a la penalización asociada al caso de falta de agua en un segmento de río;
- Los términos ($MinXD_{n,d}^{t-}$) y ($MaxXD_{n,d}^{t+}$) están relacionados con la penalización de no alcanzar el volumen mínimo y exceder la capacidad de un segmento de demanda respectivamente.

Las restricciones del problema se agregan para modelar la naturaleza continua del flujo de agua en la red y regular el flujo; y se pueden agrupar de acuerdo con seis tipos diferentes: (a) Restricciones que preservan el balance de masa del agua que fluye de un nodo al siguiente; (b) Restricciones considerando las limitaciones físicas y regulatorias tales como restricciones de capacidad de embalses y segmentos de ríos; (c) Restricciones para modelar la continuidad del flujo de agua (d) Restricciones para modelar retrasos temporales en el proceso de transporte de agua, debido, p. para devolver el flujo de agua inundada; (e) Restricciones relacionadas con la pérdida de agua; y (f) Restricciones para modelar el exceso de agua (inundaciones). Estas restricciones, así como el significado de cada variable es visible en los anexos de este estudio. También se definen parámetros a ser calibrados para modelar de manera más cercana a la realidad el flujo del agua en el río. Los parámetros a calibrar con los valores por defecto, así como el valor de las penalidades en la función objetivo son visibles en la Fig. 8, que también fueron usados en (Veintimilla-Reyes et al., 2019).

Type	Notation	Description	Unit	Value Use Case
Penalties	P_d	Penalty for not meeting the demand with one unit	euro/hm ³	1.0
	E_d	Penalty for exceeding the demand with one unit	euro/hm ³	20.0
	F_n	Penalty for not meeting the minimum river segment capacity with one unit	euro/hm ³	5.0
	G_n	Penalty for exceeding the maximum capacity in a demand segment with one unit	euro/hm ³	20.0
	W_n	Penalty for having a one unit flood in segment (n, n+1)	euro/hm ³	4.0
	B_n	Penalty not meeting the minimum capacity in a demand segment (n, n+1) with one unit	euro/hm ³	2.0
	U_n	Penalty for not meeting the minimum capacity of a reservoir with one unit	euro/hm ³	8.0
Parameters	A_n	Penalty for exceeding the maximum capacity of a reservoir with one unit	euro/hm ³	7.0
	$\alpha_{n,n+1}^t$	Loss factor associated with the river segment (n, n+1) at time (t)—to be calibrated	-	0.1%
	$\mu_{n,n+1}^t$	Time delay factor associated with the water excess in a river segment (n, n+1) at time (t) to be calibrated	-	0.1%
	$\Delta_{n,n+1}^t$	Loss factor associated with the water excess in a river segment (n, n+1) at time (t) to be calibrated	-	20%
	β_n^t	Percentage of water that must flow from the nth node to the next one at time (t), to be calibrated	-	10%
	γ_n^t	Percentage of water that must remain in the nth node until the next time step (t), to be calibrated	-	1%
	$\delta_{n,n+1}^t$	Percentage of water that comes to the next node with a time delay in time step (t) to be calibrated	-	0.1%
	θ_r^t	Loss factor associated to a reservoir to be calibrated	-	0.1%
Note: Penalty values are assigned in order to establish priorities over constraints				

Fig. 8. Penalizaciones y parámetros con su valor asignado para este caso de estudio (Veintimilla-Reyes et al., 2019). Los valores de los parámetros se calibrarán.

4.4. Selección de los métodos heurísticos.

De acuerdo a la revisión de literatura del capítulo 3, sección 3.2, se selecciona el algoritmo de optimización de enjambre de partículas o PSO (Particle Swarm Optimization) como algoritmo a ser modelado y probado en esta tesis para determinar si es efectivo para el problema de la

distribución del agua en la cuenca del río Machángara. En esta sección se aborda la parte teórica de PSO para tener conocimiento del funcionamiento del algoritmo y las herramientas disponibles para su implementación. No se abordó los conceptos de este algoritmo con anterioridad debido a la necesidad de definir a través de la revisión de literatura que algoritmo era el ideal de acuerdo a otros estudios para este problema.

Otra razón para seleccionar a PSO como algoritmo para este problema es la consideración del trabajo previo a esta tesis, donde se resolvió el problema con programación lineal. Los problemas planteados con programación lineal pueden ser resueltos con distintos enfoques como redes neuronales simplificadas (Oskoei y Mahdavi-Amiri, 2006), redes neuronales recurrentes (Malek y Alipour, 2007) y PSO (Kuo, 2009).

4.4.1. PSO (Particle Swarm Optimization)

Optimización de Enjambre de partículas o PSO por sus siglas en inglés, es un algoritmo que se diferencia de otros algoritmos de optimización en que solo se necesita la función objetivo; y no depende del gradiente ni de ninguna forma diferencial del objetivo. Otra de sus ventajas es que tiene muy pocos hiperparámetros.

PSO es una solución heurística porque nunca se puede probar que se ha encontrado la solución óptima global real y, por lo general, no se encuentra. Sin embargo, a menudo la solución encontrada por PSO está bastante cerca del óptimo global. PSO se utiliza mejor para encontrar el máximo o mínimo de una función definida en un espacio vectorial multidimensional.

La optimización de enjambre de partículas fue propuesta por Kennedy y Eberhart en 1995. Como se menciona en el artículo original (Kennedy & Eberhart, 1995), los socio-biólogos creen que un banco de peces o una bandada de pájaros que se mueve en grupo “puede beneficiarse de la experiencia de todos los demás miembros”.

El algoritmo comienza con una cantidad de puntos aleatorios en el plano llamados partículas, los cuales buscan el punto mínimo en direcciones aleatorias. En cada paso, cada partícula debe buscar alrededor del punto mínimo que haya encontrado, así como también alrededor del punto mínimo encontrado por todo el enjambre de partículas. Después de ciertas iteraciones, se considera el punto mínimo de la función como el punto mínimo explorado por este enjambre de partículas. Transportando este comportamiento en ecuaciones, la partícula i tiene una posición X y una velocidad V en la iteración t . La posición se define como se indica en la Eq (2), mientras que la velocidad se define como en Eq (3).

$$X^i(t + 1) = X^i(t) + V^i(t + 1) \text{ Eq (2)}$$

$$V^i(t + 1) = w * V^i(t) + c_1 r_1 * (pbest^i - X^i(t)) + c_2 r_2 * (gbest^i - X^i(t)) \text{ Eq (3)}$$

La Eq (2) indica que la posición de la partícula i en la iteración $t+1$ será igual a la posición de la misma partícula en la iteración t sumado la velocidad de la partícula en la iteración $t+1$. Para la velocidad en $t+1$ se usa la Eq (3) que suma la velocidad actual de la partícula que esta multiplicada por la constante de peso de inercia, más la velocidad hacia la mejor posición local y más la velocidad hacia la mejor posición global. La Eq (3) hace uso de los hiperparámetros de PSO, los cuales se definen como:

- r_1 y r_2 => son valores aleatorios entre 0 y 1.
- Las constantes w , c_1 y c_2 => son parámetros del PSO
- w => la constante de peso de inercia (inertia weight constant) => Está entre 0 y 1. Determina cuánto debe mantener la partícula su velocidad anterior (es decir, la velocidad y la dirección de la búsqueda).
- Coeficientes c_1 (cognitivo) y c_2 (social) => Controlan cuánto peso se debe dar entre refinar el resultado de la búsqueda de la propia partícula y reconocer el resultado de la búsqueda del enjambre. Podemos considerar que estos parámetros controlan el equilibrio entre exploración y explotación.
 - o Un c_1 alto junto con valores bajos de c_2 a menudo pueden hacer que el enjambre se estanque. Lo contrario puede hacer que el enjambre converja demasiado rápido, lo que resulta en soluciones subóptimas.
- $Pbest$ y $gbest$ se actualizan en cada iteración para reflejar la mejor posición encontrada hasta el momento. $Pbest$ es la mejor posición individual o personal de la partícula, mientras que $gbest$ es la mejor posición global o la mejor posición encontrada por todo el enjambre de partículas.

4.4.1.1. Conceptos utilizados por PSO y su significado.

Hay ciertos conceptos en PSO que son necesarios comprender para implementar el algoritmo en un problema o caso de uso específico. Estos conceptos pueden ser de ayuda para construir algoritmos híbridos o ayudar a encontrar una razón de porque el algoritmo resuelve o no el problema planteado.

4.4.1.1.1. Función Objetivo.

PSO evalúa la calidad de sus soluciones con una función objetivo, función de aptitud o función de evaluación $F(x)$. Se encuentran tres tipos de mejores soluciones (o posiciones) hasta el momento: la mejor individual (p_{best}), la mejor global (g_{best}) y el mejor local (l_{best}).

4.4.1.1.2. Vecindarios.

Se conoce como vecindario a la estructura social de un enjambre e indica con qué partículas debe interactuar una partícula. Dentro de un vecindario las partículas interactúan, se comunican y comparten información. Para formar una vecindad, no se restringe únicamente a las distancias físicas entre partículas; a menudo se definen por las etiquetas de enumeración de las partículas en PSO. También hay que considerar que los vecindarios pueden superponerse y una partícula puede pertenecer a múltiples vecindarios.

Diferentes estructuras vecinales pueden afectar el desempeño del enjambre. Esto debido a que determinan cómo se propaga la información entre las partículas y, por lo tanto, pueden afectar la convergencia de las partículas. Es decir, la estructura vecinal puede influir en cuándo y cómo las partículas pueden unirse, llegar a un estado estable y dejar de mejorar la solución.

En el contexto de PSO y los vecindarios, a menudo se usan dos términos, local versus global. “Local” se refiere a un vecindario individual, mientras que “global” se refiere a todo el enjambre como un gran vecindario.

4.4.1.1.3. Velocidad en PSO.

Considerando los conceptos de vecindarios y los tres tipos de soluciones posibles con la función objetivo, las partículas comparten información de diferentes maneras y puede haber tres formas de calcular las velocidades a partir de esta información:

- *Solo pbest individual o una partícula por vecindario:* cada partícula toma decisiones por sí misma
- *Gbest global y pbest individual:* cada partícula considera el conocimiento de todas las partículas dentro de un solo vecindario
- *Vecindarios locales lbest y partícula individual pbest:* la partícula considera la mejor posición local y su posición individual.

Todas las partículas siguen actualizando las velocidades y sus posiciones hasta que se alcanza el tiempo de espera o se obtiene un valor de la función objetivo deseado.

4.4.1.1.4. Beneficios de PSO

Una propiedad interesante de este algoritmo que lo distingue de otros algoritmos de optimización es que no depende del gradiente de la función objetivo. En el descenso de gradiente, por ejemplo, se busca el mínimo de una función moviéndose hacia la dirección de donde la función desciende más rápido. Para cualquier partícula en esta posición en el momento t , la forma en que se mueve no depende de en qué dirección es la "cuesta abajo", sino solo de dónde están pbest y gbest. Esto hace que PSO sea particularmente adecuado si la diferenciación es difícil en la función objetivo.

Otra propiedad de PSO que representa un beneficio es que se puede paralelizar fácilmente. Como se está manipulando múltiples partículas para encontrar la solución óptima, cada partícula se puede actualizar en paralelo y solo se necesita recopilar el valor actualizado una vez por iteración. Esto hace que arquitecturas como map-reduce sean candidatas perfectas para implementar PSO con paralelización.

Un beneficio más de PSO es que no tiene tantos parámetros que ajustar para obtener un rendimiento aceptable, además, Hu y Eberthart sugieren que PSO es aplicable tanto para problemas con restricciones como sin restricciones, incluso sin transformar previamente las restricciones y los objetivos de un problema(Lin, 2005).

4.4.1.2. Debilidades

Como todo algoritmo, PSO presenta también debilidades que deben ser consideradas al momento de resolver un problema usando este método, sobre todo con la versión genérica. PSO tiene la capacidad de converger rápidamente, pero tiende a vagar y disminuir la velocidad a medida que se acerca a un punto óptimo (Lin, 2005).

Otra debilidad que presenta es que tiende a la convergencia prematura y se atasca con bastante facilidad sin explorar lo suficiente, y en problemas multimodales puede quedar atascado en un óptimo local sin hallar el óptimo global.

Uno de los beneficios mencionados es no hay muchos parámetros para controlar, sin embargo, algunos de los parámetros dependen del problema. Existen valores sugeridos y configuraciones experimentales, pero todavía están en la etapa de prueba y error.

4.4.1.3. Variaciones

Las investigaciones y estudios sobre PSO se han centrado principalmente en cómo determinar los hiperparámetros o variar sus valores a medida que avanzaba el algoritmo (Lin, 2005). Por ejemplo, hay propuestas que hacen que el peso de inercia w sea linealmente decreciente. También hay propuestas que intentan hacer que el coeficiente cognitivo disminuya mientras que el coeficiente social aumenta para traer más exploración al principio y más explotación al final. Pero como se mencionó en la sección anterior, algunos parámetros pueden depender del problema, y los valores finales dependen del mismo, pero se puede aplicar estos cambios en tiempo de ejecución para ir probando distintos valores de los parámetros y encontrar el mejor valor para el problema.

4.4.2. Manejando Restricciones en PSO.

La partícula mientras se mueve en el espacio puede violar una o más restricciones. Para evitar estas violaciones se han desarrollado ciertas estrategias para evitar esta situación. Una de las opciones es usar funciones de conteo de conflictos y otra de estimación de distancia (Lin, 2005). Con el conteo de restricciones se penaliza cuando se viola una restricción, y la de distancia calcula la distancia desde la solución potencial hacia la satisfactoria.

Otra opción es reparar las soluciones potenciales para mejorar la búsqueda o lograr una minimización en las violaciones de restricciones. Esta estrategia es la utilizada en esta tesis junto

con el paquete de Pymoo para mejorar los resultados, sin embargo, ninguna de las estrategias asegura que la solución potencial no violará ninguna restricción.

4.5. Modelamiento del problema.

Para el modelamiento del problema con PSO, se utiliza el paquete Pymoo(Blank & Deb, 2020) disponible para Python y diversos sistemas operativos. Este paquete es un framework que ofrece algoritmos de optimización de un solo objetivo y multiobjetivo, junto con funciones relacionadas con la optimización como la visualización y la toma de decisiones. En general, se centra en la optimización multiobjetivo, sin embargo, ofrece el algoritmo de PSO como parte de su familia de algoritmos disponibles. La ventaja que ofrece este paquete es la posibilidad de modificar hiperparámetros, modificar valores de las partículas en tiempo de ejecución, manejo de restricciones de igualdad y desigualdad, y métricas de desempeño. Sin embargo, tiene una limitante y es que la mayoría de los algoritmos en Pymoo no manejarán las restricciones de igualdad de manera eficiente, esto se debe a que la rigurosidad de las restricciones de igualdad hace que sea difícil manejarlas al resolver problemas de optimización de tipo caja negra. Este es el caso del algoritmo de PSO, sin embargo, se tienen estrategias que permiten disminuir el número de restricciones de igualdad violadas.

Para modelar el problema con Pymoo, se define una sola matriz X que contendrá en cada fila una partícula y en cada una de estas, las columnas representan las variables del problema. Es decir, si un problema tiene una dimensión D de variables con un número de partículas N , la matriz X tendrá un tamaño de $N \times D$. Esto es importante considerar ya que representa espacio en memoria y limita el número de partículas que pueden participar en la búsqueda. El valor del número de partículas por defecto en Pymoo es de 25, y el caso de uso a plantearse tiene la cantidad de variables igual al número de días considerado en la etapa por la cantidad de variables planteadas en el modelamiento. Por ejemplo, para el caso de la etapa de la calibración donde se consideran las fechas de 1998 a 2001, se tiene un total de 590338 variables. Este número de variables estará presente en cada partícula, lo que produce la matriz de 25×590338 . También es necesario tener seguimiento de la posición que ocupa cada variable para construir las restricciones, y esto es implementando a través de diccionarios con Python.

Luego de definir la matriz de partículas, se define las restricciones de igualdad y desigualdad. Al igual que en el caso de las variables, el número de restricciones varían en cada etapa debido al número de días que se considera en cada etapa. En el caso de la etapa de calibración, se tiene

un total de 280615 restricciones de igualdad ($=0$) y 46462 de desigualdad (<0). En la Tabla 4 se puede observar el total de variables y restricciones codificadas en Python a través de estructuras como diccionarios y listas, y que luego serán usadas por el algoritmo PSO con Pymoo.

Tabla 4. Numero de variables, restricciones de igualdad y restricciones de desigualdad para cada etapa del problema.

Etapa	Numero de variables	Numero de restricciones de igualdad ($=0$)	Numero de restricciones de desigualdad (<0)
Calibración (1998-2001)	590 338	280 615	46 462
Validación (2002-2003)	293 552	139 532	23 070
Ejecución (2004-2005)	293 974	139 725	23 102

4.5.1. Paralelización

La paralelización en la optimización es esencial y puede acelerar significativamente el proceso. Para los algoritmos basados en la población como PSO, Pymoo permite paralelizar la evaluación de un conjunto de soluciones (Blank & Deb, 2020). Una de las formas para paralelizar es a través de un objeto llamado starmap, que se lo pasa al problema modelado con PSO para usarlo en la paralelización. La interfaz de starmap se define en la función multiprocessing.Pool.starmap de la biblioteca estándar de Python, que define un grupo de procesos que controla un grupo de procesos de trabajo (workers) a los que se pueden enviar trabajos. Admite resultados asincrónicos con tiempos de espera y devoluciones de llamada y tiene una implementación de mapa paralelo (Python, 2022). Para hacer uso del objeto starmap se debe construir una piscina de hilos de ejecución, y en este caso se definen 16 hilos de ejecución, que se definieron en un proceso de prueba-error.

4.5.2. Manejo de restricciones.

Como se mencionó con anterioridad, Pymoo indica que el manejo de restricciones de igualdad presenta un desafío y no se garantiza su cumplimiento. Sin embargo, se dispone de una función de reparación, que permite reparar los valores de las variables que participan en las restricciones. De esta forma se tiene una posibilidad mayor de cumplir con las restricciones. Para implementar

la función de reparación se debe codificar nuevamente las restricciones, pero esta vez modificando los valores de cada variable dentro de cada partícula en función de las restricciones. Pese a que la probabilidad de cumplir con las restricciones incrementa, no es garantía que se cumplirá con todas, pero se reduce el número de violaciones. En este caso permitió obtener mejores resultados en la cantidad de agua presente en los reservorios, que en un principio no estaban respetando las restricciones de máxima y mínima capacidad.

4.5.3. Hiperparámetros de PSO.

PSO tiene 5 hiperparámetros en el modelamiento del comportamiento de las partículas. ω representa el peso de inercia, c_1 y c_2 son dos valores de ponderación para equilibrar la explotación de la mejor posición personal de la partícula y la mejor posición global del enjambre, r_1 y r_2 son valores aleatorios para la actualización de velocidad. El paquete de Pymoo trata estos parámetros de manera similar a lo planteado en (Zhi-Hui Zhan et al., 2009).

- 1) **Adaptación del peso de inercia:** como se mencionó anteriormente, ω en PSO se utiliza para equilibrar las capacidades de búsqueda global y local. Muchos investigadores han defendido que el valor de ω debería ser grande en el estado de exploración y pequeño en el estado de explotación. Sin embargo, no es necesariamente correcto disminuir ω puramente con el tiempo. El factor evolutivo f comparte la característica de que también es relativamente grande durante el estado de exploración y se vuelve relativamente pequeño en el estado de convergencia. En (Zhi-Hui Zhan et al., 2009) aplican un mapeo de ω con el factor evolutivo, partiendo del valor de 0,9.
- 2) **Control de los Coeficientes de Aceleración c_1 y c_2 :** En (Zhi-Hui Zhan et al., 2009) plantean un control adaptativo para los coeficientes de aceleración en base a la siguiente noción: El parámetro c_1 representa el "autoconocimiento" que lleva a la partícula a su mejor posición histórica, ayudando a explorar nichos locales y manteniendo la diversidad del enjambre. El parámetro c_2 representa la "influencia social" que empuja al enjambre a converger a la mejor región global actual, ayudando con una convergencia rápida. Ambos coeficientes de aceleración se inicializan en 2.0 y se controlan de forma adaptativa de acuerdo con el estado evolutivo, con la estrategia de "disminución de c_1 y aumento de c_2 en un estado de salto". Esta estrategia indica que cuando la mejor partícula global salta fuera del óptimo local hacia un mejor óptimo, es probable que esté lejos del grupo acumulado. Tan pronto como una partícula encuentre esta nueva región, que se convierte en el (posiblemente nuevo) líder, otros deberían seguirla y volar a esta nueva región lo

más rápido posible. Un c2 grande junto con un c1 relativamente pequeño ayuda para obtener este objetivo.

En la Fig. 9 se puede observar una sección de la tabla de ejecución para la etapa de calibración donde es visible este manejo de los hiperparámetros de PSO para tener un mejor resultado.

n_gen	n_eval	w	c1	c2
1	25	0.9000000000	2.0000000000	2.0000000000
2	50	3.692361E-45	2.0000000000	2.0238188953
3	75	3.692361E-45	1.9883969814	2.0376654090
4	100	3.692361E-45	1.9759735018	2.0489968173
5	125	3.692361E-45	1.9642303054	2.0562892246
6	150	3.692361E-45	1.9549649778	2.0668588726
7	175	3.692361E-45	1.9453143508	2.0774630672
8	200	3.692361E-45	1.9357322533	2.0919478665
9	225	3.692361E-45	1.9236143226	2.0986375583
10	250	3.692361E-45	1.9141240174	2.1047003817
11	275	3.692361E-45	1.9066318003	2.1136684749
12	300	3.692361E-45	1.8994507351	2.1295534105
13	325	3.692361E-45	1.8873440097	2.1336156437

Fig. 9. Manejo de valores de hiperparámetros por parte de Pymoo.

4.5.4. Modelamiento en PSO para el número de reservorios óptimo de acuerdo al problema planteado.

En (Veintimilla-Reyes et al., 2019) se extiende el modelo LP a un modelo de programación lineal entera mixta (MILP). De este modo los autores son capaces de seleccionar los nodos en la red donde la construcción de reservorios adicionales de una capacidad predefinida mejoraría aún más la asignación de agua. El objetivo de esta extensión es determinar si el desempeño actual de la WSN se puede mejorar al incluir un nuevo reservorio en una o más ubicaciones candidatas. Siguiendo esta extensión se lleva a cabo un proceso similar de mejora en la asignación del agua con la inclusión de reservorios nuevos.

4.5.4.1. Definiendo las ubicaciones candidatas para los reservorios.

La configuración de red para la cuenca del río Machángara para la asignación del agua contiene 4 nodos de reservorio, 16 nodos de transferencia y 6 nodos de demanda. Los nodos están conectados por segmentos que permiten la transferencia de agua entre ellos. El panel izquierdo de la Fig. 10 representa esta configuración de red, mientras que el panel derecho muestra la configuración a la que se aplicará el modelo con las ubicaciones candidatas para nuevos reservorios que incluyen todos los nodos de reservorio existentes y los nodos de transferencia.

Los parámetros, variables y variables de holgura para ambas configuraciones de red son los mismos, esto también se aplica a los datos de lluvia.

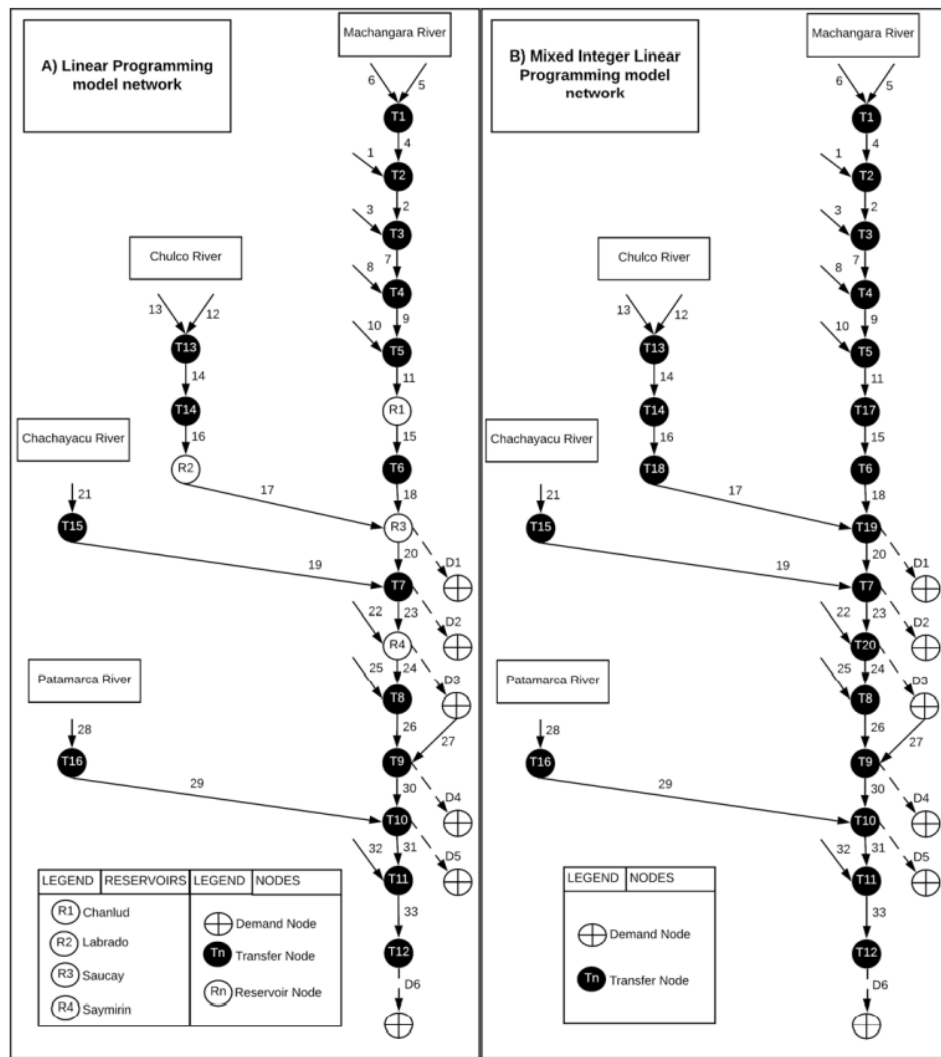


Fig. 10. Representación gráfica de la configuración de red utilizadas en (Veintimilla-Reyes et al., 2019) y también como base para construir PSO. (Izquierda) Configuración de red base. (Derecha) Configuración de red con todos los nodos como transferencia de nodos candidatos.

4.5.4.2. Modelamiento del problema con PSO.

En este modelo los nodos de transferencia se consideran “reservorios candidatos”, es decir, ubicaciones potenciales para construir reservorios con una capacidad predefinida. El modelo se formula con el propósito de determinar la ubicación de reservorios de capacidad predefinida que minimicen la suma de penalidades asociadas a la distribución de agua.

Para lograr esto se extiende el modelo de asignación de agua Eq (1), que aparte de considerar sanciones relacionadas con el incumplimiento y superación de las demandas, con la falta de agua y el desbordamiento de los reservorios, el incumplimiento del caudal mínimo y la inundación de un segmento de río, el incumplimiento del caudal mínimo o la superación de la capacidad máxima demandada en segmentos de los ríos; también se considera los costes de construcción y gestión de los embalses. Por lo tanto, la función objetivo Eq (1) se amplía para incluir una aproximación del término del costo de construcción y administración (BCn) para cada reservorio posible (Yn) (Eq. 4). Yn es una variable binaria que indica si la ubicación n se selecciona o no para construir un reservorio. Para esto es necesario codificar PSO con Pymoo considerando el nuevo tipo de variable binaria, con un límite inferior de 0 y superior de 1.

$$\begin{aligned} \text{minimize } & \sum_n \sum_t (W_n * T_{n,n+1}^{t+}) + \sum_n \sum_d \sum_t (P_n * S_{n,d}^{t-}) + \sum_r \sum_t (U_r * SH_r^{t-}) + \sum_r \sum_t (A_r * OF_r^{t+}) + \\ & \sum_n \sum_t (B_n * Q_{n,n+1}^{t-}) + \sum_n \sum_d \sum_t (E_n * S_{n,d}^{t+}) + \sum_n \sum_d \sum_t (F_n * MinXD_{n,d}^{t-}) + \sum_n \sum_d \sum_t (G_n * MaxXD_{n,d}^{t+}) + \\ & \sum_n (BC_n * Y_n) \end{aligned}$$

Eq (4) (Veintimilla-Reyes et al., 2019)

Tanto en (Veintimilla-Reyes et al., 2019) como en este estudio, se tiene en cuenta dos características principales de los reservorios candidatos:

- La capacidad de almacenamiento
- El volumen mínimo de agua que es necesario mantener en todo momento para garantizar el funcionamiento ecológico

Para considerar estas características se ajustan las restricciones de capacidad del reservorio, así como una restricción para especificar el número mínimo de reservorios solicitados (ver Fig. 11). Sin embargo, esta restricción de número mínimo de reservorios solicitados no logra ser cubierta por PSO debido a la dificultad de cumplir con las restricciones de igualdad, pese a usar el método de reparación, en este caso se configura PSO de tal forma que devuelva el número óptimo de reservorios para el mejor valor de la función objetivo encontrado.

Capacity constraints

Reservoir(s)

$$\begin{aligned} V_r^t - OF_r^{t+} - R_{r \max}^t &\leq M_r * (1 - Y_r) & \forall_t \in T \\ & & \forall_r \in R \\ -V_r^t &\leq -R_{r \min}^t + (M_r * (1 - Y_r)) & \forall_t \in T \\ & & \forall_r \in R \\ OF_r^{t+} &\leq M_r * (1 - Y_r) & \forall_t \in T \\ & & \forall_r \in R \end{aligned}$$

Fig. 11. Restricciones agregadas para el caso de los reservorios candidatos (Veintimilla-Reyes et al., 2019).

El parámetro M es un número con un valor lo suficientemente grande como para asegurar que estas ecuaciones se cumplan para todos los valores dentro de las restricciones, así el modelo puede elegir cuál de los nodos podría transformarse en un nuevo "reservorio candidato" (Winston & Goldberg, 1994). Para este caso se usa un número aleatorio de 128 bits.

4.5.4.3. *Entrada de agua, características del reservorio y demanda de agua.*

Se usan los mismos períodos de tiempo y datos que el modelo normal de asignación de agua. En la *Tabla 5* se dan las características de los "reservorios candidatos" y los cuatro reservorios existentes presentes en el sistema de río: el volumen de agua inicialmente presente, la capacidad máxima y volumen mínimo de agua que se debe mantener y un costo semestral asociados a la construcción y gestión del embalse. Estos datos son obtenidos de (Veintimilla-Reyes et al., 2019).

Tabla 5. Características de los embalses existentes y candidatos

Nodo	Reservorio	Valor inicial[hm³]	Capacidad máxima[hm³]	Capacidad mínima[hm³]	Construcción y mantenimiento en euros por dos años.
1, 2, 3	Candidatos	2.6	13	1.3	195 000
4 ... 16	Candidatos	2.6	13	2	195 000
17	R1	5	6.15	1.23	150 000
18	R2	15	16.3	3.26	215 000
19	R3	0.7	1	0.2	100 000
20	R4	0.7	1	0.2	100 000

4.6. **Calibración, validación y aplicación del modelo.**

Con el objetivo de mantener el mismo contexto para la comparación entre el método de programación lineal con el método heurístico, en esta sección se busca cumplir con las tres fases de calibración, validación y ejecución que también fue realizado con el método de programación lineal. Sin embargo, es necesario recalcar que los retos enfrentados en cada fase son distintos a los enfrentados por la programación lineal. Al tener un grupo de partículas(soluciones) que van

buscando la mejor solución en el espacio de búsqueda, la garantía de que encuentren una solución que cumpla con todas las restricciones disminuye conforme el número de partículas y restricciones aumenta, en especial cuando se trata de PSO (Jayaram, 2017). Es necesario calibrar siete parámetros del modelo, que están enumerados en la *Tabla 6*. Como se mencionó en el estudio previo de programación lineal, los datos observados sobre disponibilidad de agua y caudal en el sistema del río no estaban disponibles, por lo que se toma como referencia el caudal de agua en los nodos de la configuración del río calculado por la herramienta ArcSWAT.

Tabla 6. Parámetros del modelo y los valores por defecto asignados

Parámetro	Símbolo	Valor por defecto
Perdida	α	0.001
Perdida en agua inundada	Δ	0.01
Retrasos de tiempo	δ	1×10^{-5}
Retrasos de tiempo en agua inundada	μ	0.001
Agua mínima a quedarse	β	0.01
Agua máxima a quedarse	γ	0.1
Pérdida en reservorios	θ	0.001

Para la calibración se utilizan los datos del período 1998-2001, para la validación se considera el período 2002-2003 y finalmente en la fase de ejecución se usa el período 2004-2005. Para las fases de calibración y validación se configura el problema con las demandas de agua en cero, de este modo el problema se enfoca en la simulación antes que en la optimización. En el caso de PSO es necesario determinar un número de partículas, iteraciones e hilos de ejecución. La máquina donde se va a ejecutar tiene las siguientes características:

- Procesador Intel(R) Core (TM) i7-7700HQ CPU @ 2.80GHz
- 32 GB de memoria RAM
- Sistema operativo: Windows
- Lenguaje de programación utilizado: Python

- Paquete para la implementación de PSO: Pymoo (Blank & Deb, 2020)

Se utiliza un enfoque prueba-error para determinar el número de iteraciones y de partículas soportadas por la máquina, resultando en:

- Numero de partículas: 25
- Numero de iteraciones: 30
- Numero de hilos: 16

El número de variables, restricciones y funciones evaluadas varía en cada fase, debido a que los períodos de tiempo son distintos en cada uno, y el número de variables y restricciones depende del número de saltos(días) en dicho período. Otro aspecto a resaltar es que el paquete utilizado para la implementación de Pymoo indica en su documentación que la mayoría de los algoritmos en Pymoo no manejarán las restricciones de igualdad de manera eficiente. Una razón es la rigurosidad de las restricciones de igualdad que hace que sea difícil manejarlas al resolver problemas de optimización de caja negra (Blank & Deb, 2020). En problemas con pocas variables y restricciones los algoritmos de Pymoo tienen un buen desempeño resolviendo las restricciones de igualdad, pero conforme aumenta el número de restricciones y variables, se vuelve más difícil manejar las restricciones para el paquete. También hay que considerar que PSO genera sus respuestas aleatorias y no se garantiza que los puntos generados aleatoriamente puedan satisfacer todas las restricciones, ni que se encontrara un punto que cumpla con las restricciones cuando son de gran numero y correlacionadas.

4.6.1. Calibración.

Para la fase de calibración se consideran los casos de uso del estudio previo para calibrar los parámetros dentro del mismo contexto. Se divide la red de la cuenca del río Machángara en cinco brazos considerando la conectividad de los segmentos como se indica en *Fig. 12*. Con un procedimiento iterativo de prueba-error se busca ajustar los parámetros en base al caso de uso indicados en la *Fig. 13* para minimizar la diferencia entre el rendimiento obtenido por PSO y el valor de referencia generado por ArcSWAT. Para evaluar el rendimiento del modelo con cada uno de los parámetros modificados se utiliza la desviación cuadrática media (RMSD). Este indicador se calcula con base en la ecuación Eq (5). Donde, P_i es el valor calculado por el modelo en PSO; O_i es el valor obtenido del modelo de referencia (ArcSWAT). Por lo tanto, este indicador

determina la desviación de la salida del modelo en PSO (valores de agua en cada nodo) del modelo de referencia (ArcSWAT).

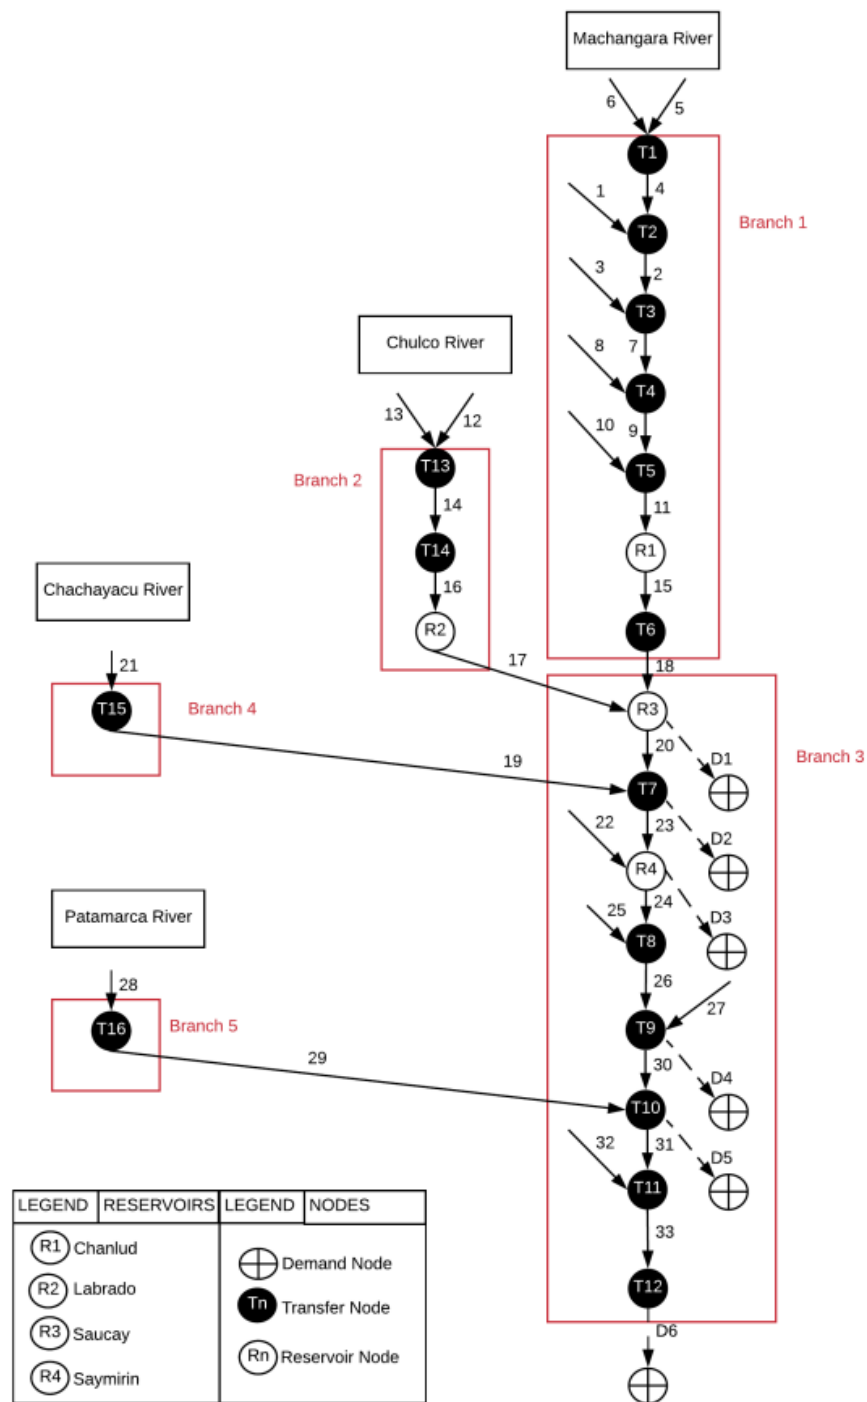


Fig. 12. Ramas de la cuenca del río Machángara utilizados para la calibración (Veintimilla-Reyes et al., 2019).

Use cases	Adapted parameter	Branch	Original value
Use case 1	-	-	-
Use case 2	Minimum water to stay (β)	1,2,3,4,5	0.01
	Maximum water to stay (γ)		0.1
Use case 3	Loss (α)	1,2,3	0.001
Use case 4	Time delays (δ)	1,2,3	0.001
Use case 5	Loss in reservoirs (θ)	1,2,3	0.001
Use case 6	Loss in reservoirs (θ)	1,2,3	1×10^{-5}
Use case 7	Time Delay Flooded Water (Δ)	1,2,3	0.01
Use case 8	Time delays (δ)	1,2,3	1×10^{-5}
Use case 9	Minimum water to stay (β)	1,2,3	0.0001
	Maximum water to stay (γ)	1,2,3	0.0002

Fig. 13. Casos de uso aplicados en (Veintimilla-Reyes et al., 2019), y también usados para la prueba y error con PSO.

$$RMSD = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}}$$

Eq (5)

Durante el procedimiento de prueba y error se llegó a notar que los parámetros no mejoraban significativamente el desempeño del algoritmo al momento de la simulación, por lo que se considera trabajar con los valores por defecto. En la Fig. 14 se puede observar la desviación cuadrática media para cada uno de los segmentos de río comparados con los valores obtenidos por ArcSWAT. El RMSD total es de 25.4494 hm³. Y el tiempo de ejecución para las 30 iteraciones fue de 2343.96 segundos (40 minutos aprox.).

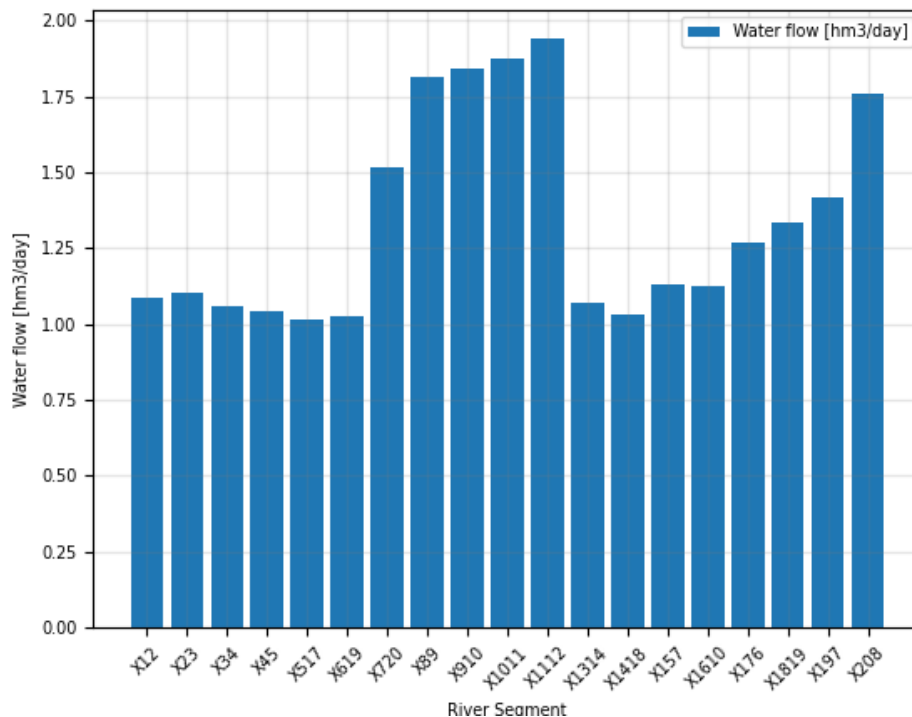


Fig. 14. Desviación cuadrática media [hm³/día] entre el flujo de agua simulado en ArcSWAT (referencia) y el flujo de agua simulado por el modelo PSO utilizando los parámetros por defecto para el período 1998-2001.

4.6.2. Validación.

Para la fase de validación se vuelve a ejecutar el modelo con PSO sin valores de demanda de agua y comparando sus resultados con la serie de tiempo ArcSWAT resultante para el período 2003-2004 (Fig. 15). Los valores de los parámetros utilizados son los definidos por defecto ya que en la fase de calibración los cambios realizados no mostraron cambios significantes en el desempeño.

El propósito del proceso de validación es verificar si los valores de los parámetros son apropiados cuando el modelo se aplica para diferentes condiciones. En esta ejecución la suma total de RSME fue de 29.5211 hm³, que tiene un valor superior al proceso de calibración, sin embargo, al modificar los parámetros, el RMSE no se ve afectado visiblemente por los parámetros. Y el tiempo de ejecución para las 30 iteraciones fue de 1595.71 segundos (27 minutos aprox.).




Fig. 15. Desviación cuadrática media [hm³/día] entre el flujo de agua simulado en ArcSWAT (referencia) y el flujo de agua simulado por el modelo LP utilizando los parámetros por defecto para el período de tiempo 2004-2005.

4.6.3. Aplicación.

El modelo calibrado y evaluado con PSO se aplica al período 2004-2005 con el propósito de asignar de manera óptima el agua disponible a los nodos de demanda considerando las demandas de agua diarias *Tabla 7* y los valores de penalización de la unidad de no cumplir o exceder estas demandas y las sanciones relacionadas con los segmentos del río, los depósitos y los segmentos de demanda. El tiempo de ejecución para las 30 iteraciones fue de 1067.01 segundos (18 minutos aprox.).

Tabla 7. Agua diaria requerida por los nodos de demanda (Promas, 2022).

Nodo	Uso	Valor(hm³/día)
D1	Central Saucay	0.621
D2	Sistema de riego Machángara	0.043

D3	Central Saymirín	0.691
D4	Sistema de agua potable de Tixán	0.121
D5	Sistema de riego Ricaurte	0.026
D6	Funcionamiento del ecosistema	0.017

La Fig. 16 muestra el volumen total de agua almacenada en cada uno de los cuatro reservorios durante el período considerado 2004-2005, donde el valor máximo corresponde a la capacidad máxima del reservorio que se muestra en la Tabla 8. En este caso, el mejor resultado encontrado por PSO consigue cumplir con algunas restricciones de mínimo y máximo de cada reservorio, pero no con todas. También se puede notar que los valores obtenidos no respetan el patrón estacional de las lluvias para la cuenca del río Machángara.

Tabla 8. Capacidades de cada reservorio en la cuenca del río Machángara.

Nodo	Reservorio	Capacidad mínima(hm³)	Capacidad máxima(hm³)
17	R1	1.23	6.15
18	R2	3.26	16.3
19	R3	0.2	1
20	R4	0.2	1

El reservorio R1 (Nodo 17) se ubica aguas arriba del río principal “Machángara”, los niveles de agua están en su mayoría entre las capacidades máxima y mínima, pero no se logra tener un flujo estable del agua, los valores tienden a ser aleatorios y no respetan los patrones de lluvia. El embalse R2 (nodo 18) también se encuentra aguas arriba, en la subcuenca “Chulco”, mientras que los embalses R3 (nodo 19) y R4 (nodo 20) están ubicados aguas abajo en el sistema fluvial y reciben agua directamente de los afluentes además de las entradas de agua reguladas a través de los embalses aguas arriba. En estos dos últimos reservorios se espera que el patrón estacional de lluvia ya no esté presente. Sin embargo, es notorio que el volumen de agua presente en cada reservorio es similar y aunque el algoritmo encuentra una respuesta que

respeta en su mayoría la restricción de máximo y mínimo volumen de agua en un reservorio, no logra representar el comportamiento del reservorio a lo largo del tiempo respetando patrones estacionales o indicando la influencia de otros reservorios o afluentes en el volumen de agua del reservorio.

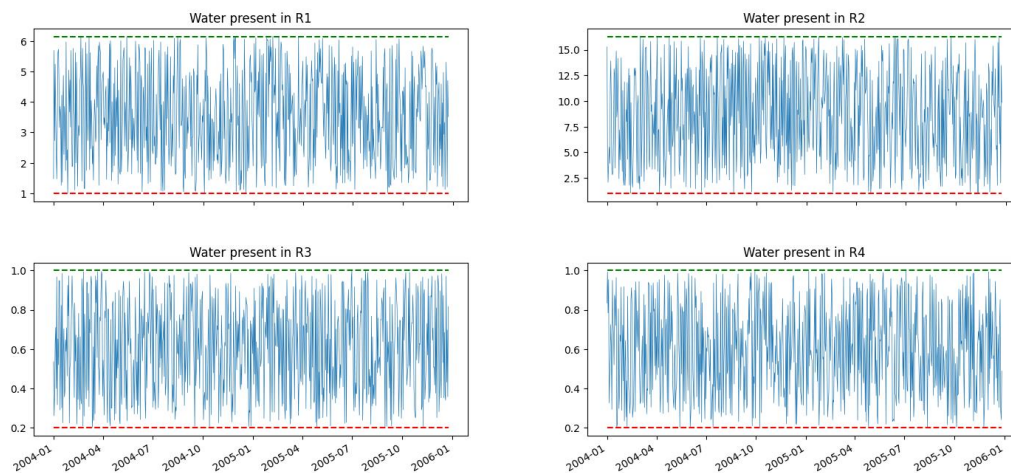


Fig. 16. Volumen de agua almacenada en los reservorios.

4.6.3.1. Penalidades

De la Tabla 9 y la Fig. 17, es claro que PSO no logra una optimización satisfactoria de la distribución del agua a lo largo de la cuenca del río Machángara. Con un total de 164 950900407.42 euros de penalidad, no se logra cumplir con el objetivo de minimización de las penalidades junto con las restricciones del problema planteado. Al igual que en el volumen de agua presente en el reservorio, PSO obtiene valores que cumplen con ciertas restricciones y viola otras, además de que no consigue respetar los patrones estacionales.

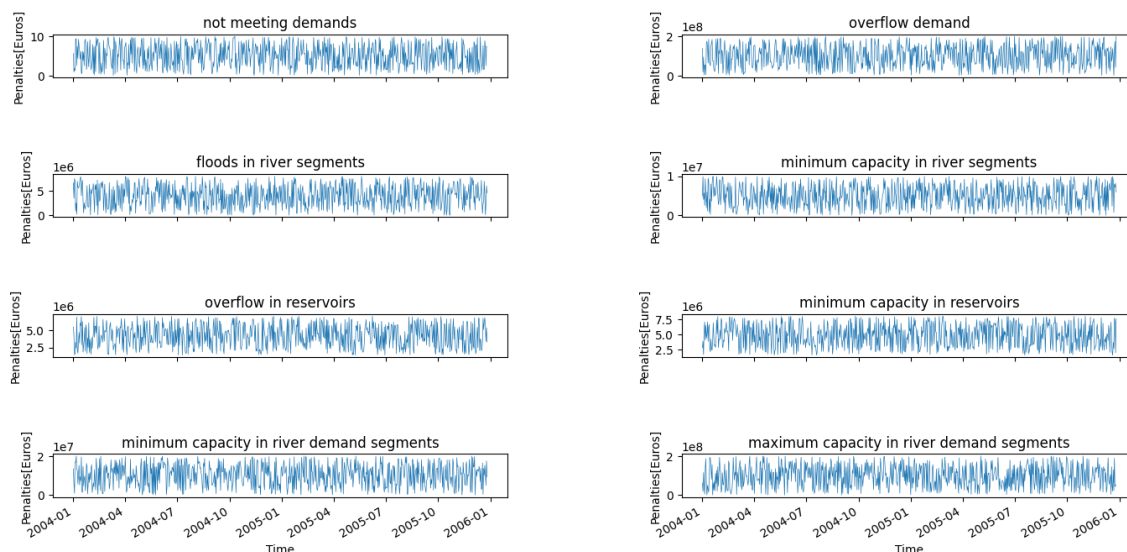


Fig. 17. Penalidades en el período 2004-2005.

Tabla 9. Desviación del volumen de agua pretendido respecto del volumen conseguido tras la optimización (hm³) y penalizaciones asociadas (€)

Causa de la penalidad	Volumen [hm ³]	Valores [euros]
(A) Sanción por no atender las demandas	3 696.02	3 696.02
(B) Sanción por inundación de las demandas	3 656.93	73 138 624 526.29
(C) Sanción por inundaciones en tramos de río	725.61	2 902 452 589.12
(D) Sanción por no cumplir con la capacidad mínima en los tramos de río	717.12	3 585 641 307.33
(E) Penalización por inundaciones en reservorios	434.52	3 041 687 022.49
(F) Sanción por no cumplir con la capacidad mínima en reservorios	437.34	3 498 729 001.97

(G) Sanción por no cumplir con la capacidad mínima en segmentos de demanda	3721.47	7 442 948 422.93
(H) Penalización por inundación en segmentos de demanda	3567.04	71 340 813 841.23
Total (A) + (B) + (C) + (D) + (E) + (F) + (G) + (H)	16956.08	164 950 900 407.42

4.7. Definición de los indicadores estadísticos para poder comparar los resultados de cada modelo.

El objetivo de definir los indicadores estadísticos es poder compararlos entre ellos, para determinar el desempeño de dos métodos de solución del problema de optimización de la distribución de agua en la cuenca del río Machángara. El primer método es el abordado en (Veintimilla-Reyes et al., 2019) que utiliza un modelo matemático exacto conocido como programación lineal (LP), mientras que el segundo método es un modelo heurístico conocido como Particle Swarm Optimization (PSO). Considerando los datos disponibles de ambos métodos, se define comparar los siguientes aspectos entre los métodos:

- Promedio y RMSD de restricciones violadas en cada etapa (calibración, validación, ejecución)
- RMSD total en cada etapa de la cantidad de agua en los segmentos de río comparados con los valores simulados por ArcSWAT.
- Promedio de volumen de agua y valor en euros al momento de incumplir con una demanda.

5. Resultados y discusión.

5.1. Comparación.

En primer lugar, se calcula el promedio para las restricciones violadas en cada etapa para el algoritmo de PSO. En el caso de la programación lineal, ninguna restricción fue violada, pero en el caso de PSO no se logra cumplir con todas las restricciones en cada partícula debido a que la mayoría de los algoritmos en Pymoo, el paquete usado para la implementación de PSO en este caso de estudio, no maneja las restricciones de igualdad de manera eficiente. Una razón de esta situación es la rigurosidad de las restricciones de igualdad que hace que sea especialmente difícil manejarlas al resolver problemas de optimización de caja negra (Blank & Deb, 2020). Para cada grupo de restricciones se espera que estas sean igual a cero, de acuerdo a como se ingresan las restricciones con el paquete de Pymoo para PSO, por lo que el promedio y RMSD de un grupo de restricciones ideal sería igual a cero. La *Tabla 10* corresponde a la etapa de calibración, la *Tabla 11* a la etapa de validación y la *Tabla 12* corresponde a la etapa de ejecución. Se puede observar que en las tres etapas las restricciones relacionadas a la continuidad máxima de agua son cumplidas a su cabalidad. Mientras que las restricciones relacionadas a las capacidades del flujo de agua son las que mayor problema presenta PSO para cumplir con la restricción. También se puede ver que las restricciones de las capacidades mínimas y máximas de los reservorios son violadas, lo que indica que ciertos picos y valles de la cantidad de agua presente en los reservorios de la Fig. 16 sobrepasan los límites de máximo y mínimo. Hay la posibilidad de que, usando un mayor número de iteraciones, un algoritmo híbrido de PSO o usar otra familia de algoritmos heurísticos pueden tener mejores resultados en cuanto a evitar las violaciones de restricciones. En este caso, es visible que la programación lineal tiene un mejor manejo de las restricciones que PSO.

Tabla 10. Promedio y RMSD de las restricciones para calibración. El valor de cero indica que no se viola ninguna restricción.

Restricción	Promedio[hm ³]	RMSD [hm ³]
Relacionadas a pérdidas de agua	0.695	2.789
Relacionadas a los nodos de demanda	5.457	24.148

Relacionadas a las pérdidas y retrasos en los nodos de demanda	0.243	0.0829
Relacionadas a las capacidades mínimas y máxima de un reservorio, así como la pérdida de agua en los mismos	4.030	24.369
Relacionadas a las capacidades de flujo	1 472.31	7 191 836.09
Relacionadas a los retrasos del flujo de agua	0.627	0.302
Relacionadas la continuidad máxima del agua	0	0
Relacionadas la continuidad mínima del agua	3.225	7.528
Relacionadas al balance de flujo de agua	3.443	10.663

Tabla 11. Promedio y RMSD de las restricciones para validación. El valor de cero indica que no se viola ninguna restricción.

Restricción	Promedio[hm³]	RMSD [hm³]
Relacionadas a pérdidas de agua	0.729	2.971
Relacionadas a los nodos de demanda	7.356	65.358
Relacionadas a las pérdidas y retrasos en los nodos de demanda	0.185	0.051
Relacionadas a las capacidades mínimas y máxima de un	4.135	25.964

reservorio, así como la pérdida de agua en los mismos		
Relacionadas a las capacidades de flujo	1 473.477	7 201 984.073
Relacionadas a los retrasos del flujo de agua	0.622	0.298
Relacionadas la continuidad máxima del agua	0	0
Relacionadas la continuidad mínima del agua	3.228	7.535
Relacionadas al balance de flujo de agua	3.491	11.456

Tabla 12. Promedio y RMSD de las restricciones para ejecución. El valor de cero indica que no se viola ninguna restricción.

Restricción	Promedio[hm3]	RMSD [hm3]
Relacionadas a pérdidas de agua	0.709	2.825
Relacionadas a los nodos de demanda	5.442	23.963
Relacionadas a las pérdidas y retrasos en los nodos de demanda	0.241	0.082
Relacionadas a las capacidades mínimas y máxima de un reservorio, así como la pérdida de agua en los mismos	3.959	23.677
Relacionadas a las capacidades de flujo	1 473.472	7 201 962.612
Relacionadas a los retrasos del flujo de agua	0.6318	0.305
Relacionadas la continuidad máxima del agua	0	0

Relacionadas la continuidad mínima del agua	3.203	7.427
Relacionadas al balance de flujo de agua	5.022	40.266

El segundo indicador a utilizar para la comparación entre los métodos de programación lineal y PSO es el RMSD total en cada etapa de la cantidad de agua en los segmentos de río comparados con los valores simulados por ArcSWAT. En la *Tabla 13* se puede observar los valores obtenidos en (Veintimilla-Reyes et al., 2019) junto con los obtenidos en este estudio con PSO.

Tabla 13. RMSD para cada etapa y por método.

Etapa [hm³ - total]	Programación Lineal	PSO
Calibración	48.34	25.44
Validación	45.77	29.52

Se puede observar en la *Tabla 14* que, pese a que PSO no cumple con todas las restricciones, para los valores de la cantidad de agua en los segmentos de río logra obtener un mejor resultado. Esto se debe a que al colocar los límites superiores e inferiores con los valores de máximo y mínimo definidos por los datos de ArcSWAT, PSO moverá sus partículas en esa área de búsqueda. La razón de que en las demás restricciones no se logre respetar en todos los casos, es porque estas restricciones son la combinación de varias variables, que, aunque respetan sus espacios de búsqueda individual, al momento de respetar el espacio de búsqueda por restricción resulta de mayor complejidad. Es por esta razón que se plantea la posibilidad de que con una mayor cantidad de iteraciones o un algoritmo híbrido que permita mover a las partículas no solo respetando sus espacios de búsqueda individuales, sino que también pueden encontrar puntos de convergencia que respete todas las restricciones.

Como indicador final se compara el promedio de volumen de agua y valor en euros al momento de incumplir con una demanda. En la *Tabla 15* se puede observar los valores para las penalidades en volumen y euros. Se puede observar que aunque en la *Tabla 14* el valor de RMSD era menor para PSO, el hecho de que no logre cumplir con las restricciones provoca que

las penalidades por no cumplir con los requerimientos del WEF-Nexus sean mucho mayores y provoque que PSO no sea un buen método para este problema de optimización mientras no se logre encontrar un punto en el espacio de búsqueda multidimensional que logre satisfacer todas las restricciones y por ende disminuya las penalidades.

Tabla 14. Comparación de valores de penalidad para LP vs PSO.

Causa de la penalidad	PSO Volumen [hm³]	PSO Valores [euros]	LP Volu men [hm³]	LP Valores [euros]
(A) Sanción por no atender las demandas	3 696.02	3 696.02	50.96	50.96
(B) Sanción por inundación de las demandas	3 656.93	73 138 624 526.29	0	0
(C) Sanción por inundaciones en tramos de río	725.61	2 902 452 589.12	0	0
(D) Sanción por no cumplir con la capacidad mínima en los tramos de río	717.12	3 585 641 307.33	0	0
(E) Penalización por inundaciones en reservorios	434.52	3 041 687 022.49	0	0
(F) Sanción por no cumplir con la capacidad mínima en reservorios	437.34	3 498 729 001.97	0.20	1.60
(G) Sanción por no cumplir con la capacidad mínima en segmentos de demanda	3 721.47	7 442 948 422.93	0	0
(H) Penalización por inundación en segmentos de demanda	3 567.04	71 340 813 841.23	0	0
Total (A) + (B) + (C) + (D) + (E) + (F) + (G) + (H)	16 956.08	164 950 900 407.42	51.16	52.56

5.2. Resultados del número de reservorios óptimo con PSO

El objetivo principal de esta extensión del modelo resuelto con PSO es determinar cuál de los nodos (reservorio/transferencia) debe convertirse en un reservorio dadas sus características predefinidas (ubicación, nivel de agua inicial, volumen mínimo y capacidad máxima) para minimizar la suma de penalidades. Los resultados del modelo que abarcan los 4 reservorios existentes (nodos 17, 18, 19 y 20) se consideran como resultados de referencia con una sanción total de 164950900407.42 euros para la etapa de ejecución. Se ejecutó el modelo extendido obteniendo un total de 11 reservorios con la penalidad mayor para la función objetivo con la extensión definida, los cuales se observan en la *Tabla 15* marcados con negrita los reservorios que son construidos. El tiempo total de ejecución con 30 iteraciones es de 1239.46 segundos (20 minutos aprox.).

Tabla 15. Reservorios construidos por PSO como mejor opción para reducir la penalidad.

Reservorios	Costo de construcción y mantenimiento	Penalidad euros
[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20]	2 145 000.0	168 196 407 013.808

Como se puede observar, no se logra ninguna mejora con la construcción de más reservorios para el caso de la resolución con PSO. En este caso, se coincide con el comportamiento encontrado en (Veintimilla-Reyes et al., 2019), donde se menciona que solo se necesita un reservorio existente para reducir la penalización total, introduciendo el criterio de que la configuración actual de la cuenca no es la óptima. Con un solo reservorio la penalización total es inferior al valor total obtenido con los cuatro embalses existentes usando MILP. En este caso con PSO, se puede observar que con 11 reservorios la penalización total no se disminuye, sino que aumenta. Es necesario mencionar que los datos de los costos de mantenimiento son aproximados y puede variar con datos reales. Para comparar con los resultados obtenidos en (Veintimilla-Reyes et al., 2019) del mejor valor obtenido con un solo reservorio en el sistema(R19), se construye el modelo de manera que se construya obligatoriamente el reservorio ignorando si PSO hubiera seleccionado dicha posición como la mejor para construir el reservorio en caso de que Pymoo y la naturaleza de PSO permitiera que las restricciones de igualdad se cumplan en su totalidad. Se puede observar en la *Tabla 16* que al construir únicamente el

reservorio 19 no se tiene un mejor valor de la penalidad y no se satisface de mejor manera la demanda que con los cuatro reservorios ya existentes. En este caso PSO no es la mejor opción para determinar cuántos reservorios pueden construirse debido a que no satisface las restricciones de igualdad y por ende va a aumentar la penalidad.

Tabla 16. Construcción y mantenimiento de un solo reservorio y la penalidad de las demandas no satisfechas.

Reservorios	Costo de construcción y mantenimiento	Penalidad euros
[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20]	100 000.0	166 428 876 847.788

6. Conclusiones y Recomendaciones.

6.1. Conclusiones

Para concluir, se puede apreciar que el algoritmo PSO para el caso de estudio de distribución de agua en la cuenca del río Machángara no es una buena opción para optimizar el problema planteado. Una de las razones es la dificultad que existe para las partículas y el paquete Pymoo utilizado (usado para la implementación) para encontrar puntos en el espacio de búsqueda que puedan satisfacer todas las restricciones, y por lo tanto aumentan las penalizaciones por no poder cumplir con las limitaciones y demandas del problema.

A pesar del difícil manejo de las restricciones de igualdad, es posible mejorar los resultados con estrategias como la reparación de los valores de las partículas para que estén dentro del espacio de restricciones. Sin embargo, estas estrategias no garantizan poder cumplir con todas las limitaciones y demandas.

En cuanto a la definición del número óptimo de embalses para el sistema fluvial propuesto, PSO no logra resolver el problema de manera efectiva y obtiene una respuesta que incluso puede catalogarse como aleatoria porque no cumple con las restricciones y no logra reducir la penalidad actual, sino que la aumenta.

Otro factor a destacar de por qué PSO no resultó ser un buen candidato para este caso de estudio es el número de variables a considerar en el problema, lo que limita el número de partículas e iteraciones debido a la cantidad de memoria a utilizar para llevar un seguimiento de los mismos. Esta limitación en el número de iteraciones se vuelve grave cuando se considera una de las desventajas de PSO, que es la pérdida de densidad de población (Lai et al., 2022), por lo que rara vez se produce una convergencia prematura, lo que requiere varias iteraciones para que las partículas puedan converger a un resultado óptimo global o local.

6.2. Trabajos futuros.

Es necesario mencionar que la revisión de literatura realizada previo a este estudio indica que PSO es el algoritmo más utilizado y eficiente en este tipo de problemas, pero los algoritmos PSO utilizados tuvieron mejoras que lo convirtieron en un algoritmo híbrido, por lo que para un trabajo futuro puede aplicar un algoritmo híbrido que permita resolver el problema encontrado de la satisfacción de las restricciones por parte de las partículas en el espacio de búsqueda.

Otro enfoque es aplicar el segundo tipo de algoritmo meta-heurístico, siendo los algoritmos genéticos una alternativa a probar y comparar con los resultados obtenidos con PSO y también con los obtenidos por los métodos exactos de LP y MILP.

Referencias

- Afshar, A., Massoumi, F., Afshar, A., & Mariño, M. A. (2015). State of the Art Review of Ant Colony Optimization Applications in Water Resource Management. *Water Resources Management*, 29(11), 3891-3904. <https://doi.org/10.1007/s11269-015-1016-9>
- Asgari, H.-R., Bozorg-Haddad, O., Soltani, A., & Loáiciga, H. A. (2019). Optimization model for integrated river basin management with the hybrid WOAPSO algorithm. *Journal of Hydro-Environment Research*, 25, 61-74. <https://doi.org/10.1016/j.jher.2019.07.002>
- Ashrafi, S. M., Ashrafi, S. F., & Moazami, S. (2017). Developing Self-adaptive Melody Search Algorithm for Optimal Operation of Multi-reservoir Systems. *Journal of Hydraulic Structures*, 3(1). <https://doi.org/10.22055/jhs.2017.13282>
- Babamiri, O., Azari, A., & Maro, S. (2022). *An integrated fuzzy optimization and simulation method for optimal quality-quantity operation of reservoir-river system*. 23.
- Blank, J., & Deb, K. (2020). Pymoo: Multi-Objective Optimization in Python. *IEEE Access*, 8, 89497-89509. <https://doi.org/10.1109/ACCESS.2020.2990567>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182-197. <https://doi.org/10.1109/4235.996017>
- Etapá EP. (2022). *ETAPA EP - Servicios de Telefonía, Televisión, Internet, Agua Potable, Alcantarillado de Cuenca—Ecuador > Información > Gestión ambiental > Manejo de cuencas hidrográficas > Comité de conservación de la cuenca del Machángara*. <https://www.etapa.net.ec/informacion/gestion-ambiental/manejo-de-cuencas-hidrograficas/comite-de-conservacion-de-la-cuenca-del-machangara>

- Fang, G., Guo, Y., Wen, X., Fu, X., Lei, X., Tian, Y., & Wang, T. (2018). Multi-Objective Differential Evolution-Chaos Shuffled Frog Leaping Algorithm for Water Resources System Optimization. *Water Resources Management*, 32(12), 3835-3852. <https://doi.org/10.1007/s11269-018-2021-6>
- Farrokhzadeh, S., Hashemi Monfared, S., Azizyan, G., Sardar Shahraki, A., Ertsen, M., & Abraham, E. (2020). Sustainable Water Resources Management in an Arid Area Using a Coupled Optimization-Simulation Modeling. *Water*, 12(3), 885. <https://doi.org/10.3390/w12030885>
- Fink, A. (2013). *Conducting Research Literature Reviews: From the Internet to Paper*. SAGE Publications.
- Gebre, S. L., Cattrysse, D., & Van Orshoven, J. (2021). Multi-Criteria Decision-Making Methods to Address Water Allocation Problems: A Systematic Review. *Water*, 13(2), Art. 2. <https://doi.org/10.3390/w13020125>
- Guerrero, B., Mejía-Pesántez, M., & Veintimilla-Reyes, J. (2022). Optimization Models Used in Water Allocation Problems in River Basin with Reservoirs: A Systematic Review. En K. Abad & S. Berrezueta (Eds.), *Doctoral Symposium on Information and Communication Technologies* (Vol. 1647, pp. 83-93). Springer International Publishing. https://doi.org/10.1007/978-3-031-18347-8_7
- Habibi Davijani, M., Banihabib, M. E., Nadjafzadeh Anvar, A., & Hashemi, S. R. (2016). Multi-Objective Optimization Model for the Allocation of Water Resources in Arid Regions Based on the Maximization of Socioeconomic Efficiency. *Water Resources Management*, 30(3), 927-946. <https://doi.org/10.1007/s11269-015-1200-y>

- Haro, D., Paredes, J., Solera, A., & Andreu, J. (2012). A Model for Solving the Optimal Water Allocation Problem in River Basins with Network Flow Programming When Introducing Non-Linearities. *Water Resources Management*, 26(14), 4059-4071. <https://doi.org/10.1007/s11269-012-0129-7>
- Jamshid Mousavi, S., Anzab, N. R., Asl-Rousta, B., & Kim, J. H. (2017). Multi-Objective Optimization-Simulation for Reliability-Based Inter-Basin Water Allocation. *Water Resources Management*, 31(11), 3445-3464. <https://doi.org/10.1007/s11269-017-1678-6>
- Jamshidpey, A., & Shourian, M. (2021). Crop pattern planning and irrigation water allocation compatible with climate change using a coupled network flow programming-heuristic optimization model. *Hydrological Sciences Journal*, 66(1), 90-103. <https://doi.org/10.1080/02626667.2020.1844889>
- Jayaram, M. A. (2017). *Re: How should I design PSO particles for large number of decision variables?* ResearchGate. https://www.researchgate.net/post/How_should_I_design_PSO_particles_for_large_number_of_decision_variables/59a6a18640485486247dbadd/citation/download
- Jerves-Cobo, R., Everaert, G., Iñiguez-Vela, X., Córdova-Vela, G., Díaz-Granda, C., Cisneros, F., Nopens, I., & Goethals, P. (2017). A Methodology to Model Environmental Preferences of EPT Taxa in the Machangara River Basin (Ecuador). *Water*, 9(3), 195. <https://doi.org/10.3390/w9030195>
- Kazemi, M., Bozorg-Haddad, O., Fallah-Mehdipour, E., & Loáiciga, H. A. (2020). Inter-basin hydro-politics for optimal water resources allocation. *Environmental Monitoring and Assessment*, 192(7), 478. <https://doi.org/10.1007/s10661-020-08439-3>
- Kennedy, J., & Eberhart, R. (1995). *Particle Swarm Optimization*. 7.

- Kumar, V., & Yadav, S. M. (2022). A state-of-the-Art review of heuristic and metaheuristic optimization techniques for the management of water resources. *Water Supply*, ws2022010. <https://doi.org/10.2166/ws.2022.010>
- Labadie, J. W. (2004). Optimal operation of multi reservoir systems: State-of-the-art review. *J. Water Resour. Plann. Manag*, 93-111.
- Lai, V., Huang, Y. F., Koo, C. H., Ahmed, A. N., & El-Shafie, A. (2022). A Review of Reservoir Operation Optimisations: From Traditional Models to Metaheuristic Algorithms. *Archives of Computational Methods in Engineering*, 29(5), 3435-3457. <https://doi.org/10.1007/s11831-021-09701-8>
- Lin, I.-L. (2005). *PARTICLE SWARM OPTIMIZATION FOR SOLVING CONSTRAINT SATISFACTION PROBLEMS*. 202.
- Lindfield, G., & Penny, J. (2019). Chapter 9—Optimization Methods. En G. Lindfield & J. Penny (Eds.), *Numerical Methods (Fourth Edition)* (pp. 433-483). Academic Press. <https://doi.org/10.1016/B978-0-12-812256-3.00018-X>
- Liu, D., Guo, S., Chen, X., Shao, Q., Ran, Q., Song, X., & Wang, Z. (2012). A macro-evolutionary multi-objective immune algorithm with application to optimal allocation of water resources in Dongjiang River basins, South China. *Stochastic Environmental Research and Risk Assessment*, 26(4), 491-507. <https://doi.org/10.1007/s00477-011-0505-5>
- Liu, D., Guo, S., Liu, P., Xiong, L., Zou, H., Tian, J., Zeng, Y., Shen, Y., & Zhang, J. (2018). Optimisation of water-energy nexus based on its diagram in cascade reservoir system. *Journal of Hydrology*, 569. <https://doi.org/10.1016/j.jhydrol.2018.12.010>
- Mirfenderesgi, G., & Mousavi, S. J. (2016). Adaptive meta-modeling-based simulation optimization in basin-scale optimum water allocation: A comparative analysis of meta-

- models. *Journal of Hydroinformatics*, 18(3), 446-465.
<https://doi.org/10.2166/hydro.2015.157>
- Nicklow, J., Reed, P., Savic, D., Dessalegne, T., Harrell, L., Chan Hilton, A., Karamouz, M., Minsker, B., Ostfeld, A., Singh, A., Zechman, E., & Evolutionary, A. (2010). State of the Art for Genetic Algorithms and Beyond in Water Resources Planning and Management. *JOURNAL OF WATER RESOURCES PLANNING AND MANAGEMENT-ASCE*, 136, 412-432. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000053](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000053)
- Nicklow, J., Reed, P., Savic, D., Dessalegne, T., Harrell, L., Chan-Hilton, A., Karamouz, M., Minsker, B., Ostfeld, A., Singh, A., Zechman, E., & ASCE Task Committee on Evolutionary Computation in Environmental and Water Resources Engineering. (2010). State of the Art for Genetic Algorithms and Beyond in Water Resources Planning and Management. *Journal of Water Resources Planning and Management*, 136(4), 412-432. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000053](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000053)
- Pareto, V. (1896). *Cours D'Economie Politique*. Rouge.
- Promas. (2022). *Programa para el Manejo del Agua y del Suelo – PROMAS-UNIVERSIDAD DE CUENCA | Portal Sobre Conservación y Equidad Social CES*. <https://www.portalces.org/paramos/directorio/proyectos-investigacion/programa-para-manejo-del-agua-del-suelo-promas>
- Python. (2022). *Multiprocessing—Process-based parallelism—Python 3.10.8 documentation*. multiprocessing — Process-based parallelism — Python 3.10.8 documentation. <https://docs.python.org/3/library/multiprocessing.html#multiprocessing.pool.Pool>
- Qu, G., & Lou, Z. (2013). Application of particle swarm algorithm in the optimal allocation of regional water resources based on immune evolutionary algorithm. *Journal of Shanghai*

- Jiaotong University (Science)*, 18(5), 634-640. <https://doi.org/10.1007/s12204-013-1442-x>
- Shourian, M., & Mousavi, S. J. (2017). Performance Assessment of a Coupled Particle Swarm Optimization and Network Flow Programming Model for Optimum Water Allocation. *Water Resources Management*, 31(15), 4835-4853. <https://doi.org/10.1007/s11269-017-1781-8>
- Szemis, J. M., Dandy, G. C., & Maier, H. R. (2013). A multiobjective ant colony optimization approach for scheduling environmental flow management alternatives with application to the River Murray, Australia: MULTIOBJECTIVE APPROACH FOR ENVIRONMENTAL FLOW MANAGEMENT. *Water Resources Research*, 49(10), 6393-6411. <https://doi.org/10.1002/wrcr.20518>
- Uen, T.-S., Chang, F.-J., Zhou, Y., & Tsai, W.-P. (2018). *Exploring synergistic benefits of Water-Food-Energy Nexus through multi-objective reservoir optimization schemes—ScienceDirect*.
<https://www.sciencedirect.com/science/article/abs/pii/S0048969718309318?via%3Dihub>
- Veintimilla-Reyes, De Meyer, A., Cattrysse, D., Tacuri Espinoza, E., Vanegas, P., Cisneros, F., & Orshoven, J. (2019). MILP for Optimizing Water Allocation and Reservoir Location: A Case Study for the Machángara River Basin, Ecuador. *Water*, 11. <https://doi.org/10.3390/w11051011>
- Villavicencio Riera, V. E., & Chávez Ochoa, L. M. (2011). *Estudio arqueológico de las cuencas media y baja del río Machángara*. <http://dspace.ucuenca.edu.ec/handle/123456789/1957>

- Yan, Z., Sha, J., Liu, B., Tian, W., & Lu, J. (2018). An Ameliorative Whale Optimization Algorithm for Multi-Objective Optimal Allocation of Water Resources in Handan, China. *Water*, *10*(1), 87. <https://doi.org/10.3390/w10010087>
- Yang, Y., Luo, Q., & Ye, G. (2018). Optimization of water allocation system at the river basins. *2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 482-488. <https://doi.org/10.1109/FSKD.2018.8687202>
- Zhi-Hui Zhan, Jun Zhang, Yun Li, & Chung, H. S.-H. (2009). Adaptive Particle Swarm Optimization. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, *39*(6), 1362-1381. <https://doi.org/10.1109/TSMCB.2009.2015956>

Anexos

Anexo A: Modelo matemático para la distribución del agua en la cuenca del río Machángara.

El modelo matemático fue planteado en (Veintimilla-Reyes et al., 2019) con mayor detalle en el capítulo 2. En este anexo se presentan las fórmulas y variables que fueron implementadas en Python para ser usadas por el paquete de Pymoo y resolver el problema con PSO. En la Fig. A - 1 se puede observar la función objetivo para la distribución del agua en un sistema de río con reservorios.

$$\begin{aligned} \text{Minimize } & \sum_n \sum_d \sum_t (P_d * S_{n,d}^{t-}) + \sum_n \sum_d \sum_t (E_d * \\ & S_{n,d}^{t+}) + \sum_r \sum_t (U_r * SH_r^{t-}) + \sum_r \sum_t (A_r * OF_r^{t+}) + \sum_n \sum_t (W_n * \\ & T_{n,n+1}^{t+}) + \sum_n \sum_t (B_n * Q_{n,n+1}^{t-}) + \sum_n \sum_d \sum_t (F_d * \text{MinXD}_{n,d}^{t-}) + \\ & \sum_n \sum_d \sum_t (G_d * \text{MaxXD}_{n,d}^{t+}) \end{aligned}$$

Fig. A - 1. Función objetivo para la distribución del agua en un sistema de río con reservorio.

En la ecuación de la Fig. A - 1 se tiene:

- El primer término se refiere a las demandas insatisfechas ($S_{n,d}^{t-}$) y sus correspondientes penalizaciones (P_n);
- El segundo término ($S_{n,d}^{t+}$) está relacionado con las penalidades cuando se asigna más agua de la requerida a un nodo de demanda;
- Los términos (SH_r^{t-}) y (OF_r^{t+}) están relacionados con una penalización por no alcanzar el volumen mínimo en y por exceder la capacidad máxima de los embalses respectivamente
- El quinto término ($T_{n,n+1}^{t+}$) está relacionado con la sanción por crecida de un segmento de río;
- El sexto término ($Q_{n,n+1}^{t-}$) se refiere a la penalización asociada al caso de falta de agua en un segmento de río;
- Los términos ($\text{MinXD}_{n,d}^{t-}$) y ($\text{MaxXD}_{n,d}^{t+}$) están relacionados con la penalización de no alcanzar el volumen mínimo y exceder la capacidad de un segmento de demanda respectivamente.

Las restricciones consideradas dentro del problema son visibles desde la Fig. A - 2.

a) Mass balance constraints

1. Transport (n)

$$\begin{aligned} X_{n-1,n}^t + \sum_i X_{i,n}^t + \sum_r X_{r,n}^t + V_n^{t-1} + TD_{n-2,n-1}^{t-2} + TDFW_{n-2,n-1}^{t-2} + RW_{n-1,n}^t + OF_r^{t+} + \sum_d RD_{d-2,d-1}^{t-2} &= V_n^t + LP_n^t + X_{n,n+1}^t + \sum_r X_{n,r}^t + \sum_d X_{n,d}^t + TD_{n,n+1}^t + L_{n-1,n}^t + L_{r,n}^t + L_{n,d}^t \end{aligned} \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_t \in T \\ \forall_i \in I \end{array}$$

2. Reservoir (r)

$$\sum_n X_{n,r}^t + \sum_i X_{i,r}^t + V_r^{t-1} = \sum_n X_{r,n}^t + V_r^t + \sum_n X_{r,d}^t \quad \begin{array}{l} \forall_r \in R \\ \forall_n \in N \end{array}$$

Fig. A - 2. Restricciones del balance de agua.

b) Network limitations and capacity constraints

1. Network limitations

Inputs (i)

$$\sum_i X_{i,n}^t = X_{n,n+1}^t \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_i \in I \end{array}$$

Sources (i)

$$\sum_n X_{i,n}^t = I_i^t \quad \begin{array}{l} n \in N \\ \forall_i \in I \end{array}$$

Demands (d)

$$\sum_n X_{n,d}^t + S_d^{t-} - S_d^{t+} = D_d^t \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_d \in D \end{array}$$

2. Capacity constraints

River Segment (n)

$$X_{n,n+1}^t + T_{n,n+1}^{t-} - T_{n,n+1}^{t+} = Cmax_{n,n+1}^t \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_t \in T \end{array}$$

$$X_{n,n+1}^t + Q_{n,n+1}^{t-} - Q_{n,n+1}^{t+} = Cmin_{n,n+1}^t \quad \begin{array}{l} n \in N \\ n > 1 \end{array}$$

Reservoir (r)

$$V_r^t - LP_r^t - OF_r^{t+} + OF_r^{t-} = Rmax_r^t \quad \forall_r \in R$$

$$V_r^t - LP_r^t + SH_r^{t-} - SH_r^{t+} = Rmin_r^t \quad \forall_r \in R$$

Demand segment (d)

$$X_{n,d}^t + MinXD_{n,d}^{t-} - MinXD_{n,d}^{t+} = Cmin_{n,d}^t \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_d \in D \end{array}$$

$$X_{n,d}^t + MaxXD_{n,d}^{t-} - MaxXD_{n,d}^{t+} = Cmax_{n,d}^t \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_d \in D \end{array}$$

Fig. A - 3. Restricciones para los límites de la red que representa el río.

c) Continuity constraints

$$V_n^t \leq \beta_n^t * (\sum_i X_{i,n}^{t-1} + \sum_r X_{r,n}^{t-1} + V_n^{t-1} + X_{n-1,n}^t + RW_{n-1,n}^t + TDFW_{n-2,n-1}^{t-2}) \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_i \in I \\ \forall_r \in R \end{array}$$

$$V_n^t \geq \gamma_n^t * (\sum_i X_{i,n}^{t-1} + \sum_r X_{r,n}^{t-1} + V_n^{t-1} + X_{n-1,n}^t + RW_{n-1,n}^t + TDFW_{n-2,n-1}^{t-2}) \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_i \in I \\ \forall_r \in R \end{array}$$

Fig. A - 4. Restricciones de continuidad o flujo del agua.

d) Time delay constraints

Transfer nodes

$$TD_n^t = \delta_n^t * (X_{n,n+1}^t) \quad \begin{array}{l} n \in N \\ n > 1 \end{array}$$

Flooded Water (n)

$$TDFW_{n,n+1}^t = \mu_n^t * (T_{n,n+1}^{t+}) \quad \begin{array}{l} \forall_n \in N \\ n > 1 \end{array}$$

Fig. A - 5. Restricciones de retraso del agua en cada salto de tiempo.

e) Losses

In river segment (n)

$$L_{n-1,n}^t = \alpha_{n-1,n}^t * (X_{n-1,n}^t) \quad \begin{array}{l} n \in N \\ n > 1 \end{array}$$

In segment between reservoir and transfer node (r)

$$L_{r,n}^t = \alpha_{r,n}^t * (X_{r,n}^t) \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_r \in R \end{array}$$

In segment between transfer and demand node (d)

$$L_{n,d}^t = \alpha_{n,d}^t * (X_{n,d}^t) \quad \begin{array}{l} n \in N \\ n > 1 \\ \forall_d \in D \end{array}$$

In Reservoir (r)

$$LP_r^t = \theta_r^t * (V_r^t) \quad \forall_r \in R$$

Of flooded water (n)

$$LFW_{n,n+1}^t = \Delta_{n,n+1}^t * (T_{n,n+1}^{t+}) \quad \begin{array}{l} n \in N \\ n > 1 \end{array}$$

Fig. A - 6. Restricciones para simular la pérdida de agua en el sistema de río.

f) Floods

Flood water returning to river segment (n)

$$RW_{n,n+1}^t = T_{n,n+1}^{t+} - LFW_{n,n+1}^t - TDFW_{n,n+1}^t \quad \begin{array}{l} n \in N \\ n > 1 \end{array}$$

Water returning from a demand node to a reservoir node

$$RD_{r,d}^t = (1 - \alpha_{r,d}^t) * (X_{r,d}^t) \quad \begin{array}{l} \forall_d \in D \\ \forall_r \in R \end{array}$$

Fig. A - 7. Restricciones para la simulación de inundaciones.

Las variables y su significado se detallan a continuación:

Type	Notation	Description	Unit
Indices	i	input node $\in I$	-
	r	reservoir node $\in R$	-
	d	demand node $\in D$	-
	n	transfer node $\in N$	-
	t	time step $\in T$	-
Parameters	P_d	Penalty for not meeting the demand with one unit	Monetary units (mu)/volume (uv)
	E_d	Penalty for exceeding the demand with one unit	mu/uv
	F_d	Penalty for not meeting the minimum capacity in a demand segment with one unit	mu/uv
	G_d	Penalty for exceeding the maximum capacity in a demand segment with one unit	mu/uv
	W_n	Penalty for having a one unit flood in segment (n, n+1)	mu/uv
	B_n	Penalty for not meeting the minimum capacity in segment (n, n+1) with one unit	mu/uv
	U_n	Penalty for not meeting the minimum capacity of a reservoir with one unit	mu/uv
	A_n	Penalty for exceeding the maximum capacity of a reservoir with one unit	mu/uv
	$\alpha_{n,n+1}^t$	Loss factor associated with the river segment (n, n+1) at time step (t), to be calibrated	-
	$\alpha_{r,d}^t$	Loss factor associated with the reservoir node and a demand node (r, d) at time step (t), to be calibrated	-
	$\alpha_{n,d}^t$	Loss factor associated with the transfer node and a demand node (n, d) at time step (t), to be calibrated	-
	θ_r^t	Loss factor associated to a reservoir at time step (t), to be calibrated	-
	$\mu_{n,n+1}^t$	Time delay factor associated with the water excess in a river segment (n, n+1) at time step (t), to be calibrated	-
	$\Delta_{n,n+1}^t$	Loss factor associated with the water excess in a river segment (n, n+1) at time step (t), to be calibrated	-
	β_n^t	Percentage of water that must flow from the nth node to the next one at step time (t), to be calibrated	-
	γ_n^t	Percentage of water that must remain in the nth node until the next time step (t), to be calibrated	-
	$\delta_{n,n+1}^t$	Percentage of water that flows to the next node with a time delay in time step (t), to be calibrated	-
	$Cmin_{n,n+1}^t$	Minimum capacity of the river segment (n, n+1) at time step (t)	uv




Variables	$Cmax_{n,n+1}^t$	Maximum capacity of the river segment (n, n+1) at time step (t).	uv
	$Cmin_{n,d}^t$	Minimum capacity of a demand segment (n,d) at time step (t)	uv
	$Cmax_{n,d}^t$	Maximum capacity of a demand segment (n,d) at time step (t)	uv
	I_i^t	Amount of water arriving at the input node (i) at time step (t)	uv
	$Rmax_r^t$	Maximum capacity of a reservoir at time step (t)	uv
	$Rmin_r^t$	Minimum capacity of a reservoir at time step (t)	uv
	V_n^t	Amount of water in a node (n) at time step (t)	uv
	D_d^t	Amount of water needed to meet demand (d) at time step (t)	uv
	V_r^t	Amount of water in the reservoir (r) at time step (t)	uv
	$X_{n,n+1}^t$	Flow between the nodes (n) and (n+1) at time step (t).	uv / time step
	$X_{r,n}^t$	Flow between a reservoir node (r) and a transfer node (n) at time step (t)	uv / time step
	$X_{n,r}^t$	Flow between a transfer node (n) and a reservoir node (r) at time step (t)	uv / time step
	$X_{i,n}^t$	Flow between an input node (i) and a transfer node (n) at time step (t)	uv / time step
	$X_{i,r}^t$	Flow between an input node (i) and a reservoir node (r) at time step (t).	uv / time step
	$X_{n,d}^t$	Flow between a transfer node (n) and a demand node (d) at time step (t)	uv / time step
	$X_{r,d}^t$	Flow between a reservoir node (r) and a demand node (d) at time step (t)	uv / time step
	TD_n^t	Delayed flow from upstream nodes and coming into node (n) at time step (t)	uv / time step
	$L_{n,n+1}^t$	Amount of water lost during the flow from transfer node (n) to transfer node (n+1) in time step t	uv
	$L_{r,n}^t$	Amount of water lost during the flow from reservoir node (r) to a transfer node (n) in time step t	uv
	$L_{n,d}^t$	Amount of water lost during the flow from transfer node (n) to demand node (d) in time step t	uv
	LP_r^t	Amount of water lost in a reservoir node (r) during time step t	uv
	$LFW_{n,n+1}^t$	Amount of water lost from the water flooded while flowing from node (n) to node (n+1) in time step t	uv
	$RW_{n,n+1}^t$	Amount of flooded water flowing back to a node (n+1) from node (n) during time step t	uv
	$RD_{r,d}^t$	Amount of water flowing back to a reservoir node (r) from a demand node (d) in time step t	uv
	$TDFW_{n,n+1}^t$	Amount of water flowing from node (n) to node (n+1) with a delay due to flooding in time step t	uv
Slack Variables	$S_{n,d}^{t-}$	Amount of water that cannot be allocated to demand (d) at time step (t)	uv
	$S_{n,d}^{t+}$	Amount of water that exceeds the demand (d) at time step (t)	uv
	$T_{n,n+1}^{t+}$	Amount of water above the maximum capacity of segment (n, n+1) at time step (t)	uv
	$T_{n,n+1}^{t-}$	Amount of water under the maximum capacity of segment (n, n+1) at time step (t)	uv
	$Q_{n,n+1}^{t-}$	Amount of water under the minimum capacity of segment (n, n+1) at time (t)	uv
	$Q_{n,n+1}^{t+}$	Amount of water above the minimum capacity of segment (n, n+1) at time step (t)	uv
	OF_r^{t+}	Amount of water above the maximum capacity of reservoir (r) at time step (t)	uv
	OF_r^{t-}	Amount of water under the maximum capacity of reservoir (r) at time step (t)	uv
	SH_r^{t-}	Amount of water under the minimum capacity of reservoir (r) at time step (t)	uv
	SH_r^{t+}	Amount of water above the minimum capacity of reservoir (r) at time step (t)	uv
	$MinXD_{n,d}^{t-}$	Amount of water under the minimum capacity of demand segment (n, d) at time step (t)	uv

$MinXD_{n,d}^{t+}$	Amount of water above the minimum capacity of demand segment (n, d) at time step (t)	uv
$MaxXD_{n,d}^{t-}$	Amount of water under the maximum capacity of demand segment (n, d) at time step (t)	uv
$MaxXD_{n,d}^{t+}$	Amount of water above the maximum capacity of demand segment (n, d) at time step (t)	uv

Anexo B: Artículo científico publicado de la revisión de literatura.

Se publicó un artículo dentro de esta tesis titulado “Optimization Models Used in Water Allocation Problems in River Basin with Reservoirs: A Systematic Review”, que fue presentado en TICEC 2022 y está disponible en el libro DSICT 2022 (Guerrero et al., 2022).

Optimization Models Used in Water Allocation Problems in River Basin with Reservoirs: A Systematic Review

Berenice Guerrero^{}, Magali Mejía-Pesántez^{}, and Jaime Veintimilla-Reyes^{}¹

Department of Computer Sciences, Faculty of Engineering, Universidad de Cuenca, Cuenca, Ecuador
{berenice.guerrero, magali.mejia, jaime.veintimilla}@ucuenca.edu.ec

Abstract. In recent years, several works dedicated to obtaining optimization models have been published. Many of them have been applied in the management of water resources, especially since water is a vital resource that brings economic, social and environmental benefits. The main objective of this article is to review the published literature on optimization models and understand what methods their authors used to solve optimization problems in water allocation in a river basin with reservoirs. A systematic methodology was applied to select research questions, digital databases and search terms to later use practical and methodological filters to carry out this systematic review. This procedure allowed a review and synthesis of the results obtained on the optimization models. It was found that the models resulting from the systematic review vary depending on the objectives set by the diverse authors. However, algorithms based on particle swarm optimization (PSO) have a greater presence compared to the rest of the algorithms present in this systematic review.

Keywords: Systematic review · Water allocation · River basin · Meta-heuristics · Heuristics · Reservoirs

Introduction

Water is an important resource that can be represented by a nexus known as the WEF-nexus (water-energy-food nexus). The nexus includes water supply, sewage treatment, and hydro-power generation in a reservoir water system [1]. The optimal design of a water allocation system that meets this nexus has become an urgent research topic [2].

¹ © The Author(s), under exclusive license to Springer Nature Switzerland AG 2022 K. Abad and S. Berrezueta (Eds.): DSICT 2022, CCIS 1647, pp. 83–93, 2022.
https://doi.org/10.1007/978-3-031-18347-8_7

The allocation of water in a river basin with reservoirs can be optimized to meet the demands of different nodes that seek to comply with the WEF-nexus. This optimization problem can be approached with different methods, one of them being heuristic and meta-heuristic methods [3]. These methods have been applied in other problems related to the management of water resources; including, optimization of reservoir operation, distribution of water through pipelines, expansion of the capacity of water infrastructure facilities, water conduction problems/shortest water route, etc. [4]. It should be noted that in all these studies the objectives to be optimized were exclusive to the study area. The objectives vary as the methods applied. For this reason, it is intended to carry out a systematic literature review on heuristic or meta-heuristic methods applied specifically in water allocation optimization problems in a river system with reservoirs.

As indicated above, systematic reviews focusing on water resources and heuristic methods are found in the literature, but an exclusive systematic review for optimizing water allocation in a river system with reservoirs is not found. The rest of the paper is organized as follows. Section 2 indicates the methodology used to review the optimization models systematically. Section 3 presents the results and discussion. Finally, the conclusion of the document is provided in Sect. 4.

Materials and Methods

The systematic review design responded to the purpose of collecting, selecting, evaluating and summarizing the evidence found regarding the heuristic or meta-heuristic methods that have been applied in optimization problems of water allocation in a river system with reservoirs. To carry out this systematic review, the Fink methodology was used, which consists of the following tasks: 1) Select Research Questions, 2) Select Bibliographic Databases and Websites, 3) Choose Search Terms, 4) Apply Practical Screen, 5) Apply Methodological Quality Screen, 6) Do the review and 7) Synthesize the results [5].

The systematic review began with the selection of the research questions. It was established that the main question to be answered was: What heuristic or meta-heuristic methods have been applied in water distribution optimization problems in a river system with reservoirs? Subsequently, the search sub-questions were defined, whose objective was to obtain information to delimit the field of research studied. These questions were: 1) What were the objectives of the water allocation optimization problems in the river basin? 2) What tools or solvers are used to solve optimization models? 3) What parts are involved in the optimization process? And 4) What indicators are used to analyze or validate the results of the optimization model?

Once the field of the research was defined, it was necessary to select the bibliographic databases and the websites. Google Scholar is selected because this search engine allows to incorporate personalized search strings with ‘and’ and ‘or’ operators; and also allows access to articles published in various journals and databases. To search for the primary articles to reference this work, a search string was defined, which is detailed in Table 1. The string was made up of the relevant terms and logical connectors, which made it possible to combine different terms and establish logical relationships between them. Articles referenced within the articles resulting from the search are also considered if they meet the criteria indicated in Table 1.

With the structured search string, 178 articles were retrieved. With the results obtained after applying the first filters, the articles that met the inclusion criteria were selected after reviewing titles, abstracts and keywords. Once all the filters were applied, a manual review of the articles was carried out to determine the secondary sources. A total of 43 articles were read to determine their reliability. Next, the articles were selected based on the use of an optimization method and the explanation on how to use

Table 1. Search criteria for the systematic literature review

Search string	(“heuristic” or “meta heuristic”) and (“optimization” and modeling or simulation) and (“water allocation”) and (river “basin” or “river” or river with “reservoirs”)
Search dates	2010–2022

Language	English and Spanish
Inclusion criteria	Exclusion criteria
Studies that apply heuristic or meta-heuristic methods for optimizing or simulating the allocation of water over a river basin or similar water systems. May or may not contain reservoirs	Studies focused exclusively on reservoir management, since the objective is the entire river system and not just the reservoir
Literature reviews that include heuristic or meta-heuristic methods applied in problems of optimization and/or simulation in a river system or similar	Distribution of water in cropping areas that do not consider the river system as part of the problem
Articles that include heuristics or meta-heuristics in hydro-logical projects that are similar to the allocation of water in a river system	Piped water distribution and groundwater allocation

it, the objective functions, the restrictions and the results obtained with their proposed model. In addition, the articles also had to meet the inclusion criteria detailed in Table 1. Through this selection, a total of 16 articles were obtained for the systematic review. It is worth mentioning that literature review articles related to this topic were also found, which provide an overview of heuristic methods, of which 6 literature reviews stand out.

Results and Discussion

This section presents the main findings on this systematic review and summarizes the results obtained after filtering the articles. Considering the inclusion criteria mentioned in the previous section, articles useful for this literature review were classified and can be seen in Table 1.

Research Questions

In the main research question of this literature review, which is: What heuristic or metaheuristic methods have been applied in water allocation optimization problems in a river system with reservoirs? To answer this question, the classification of heuristic algorithms mentioned in [6] should be mentioned, which can be seen in Fig. 1.

The classification showed in Fig. 1 plus the histogram (see Fig. 2) allow to observe that there is an emphasis on population-based algorithms, where algorithms of the

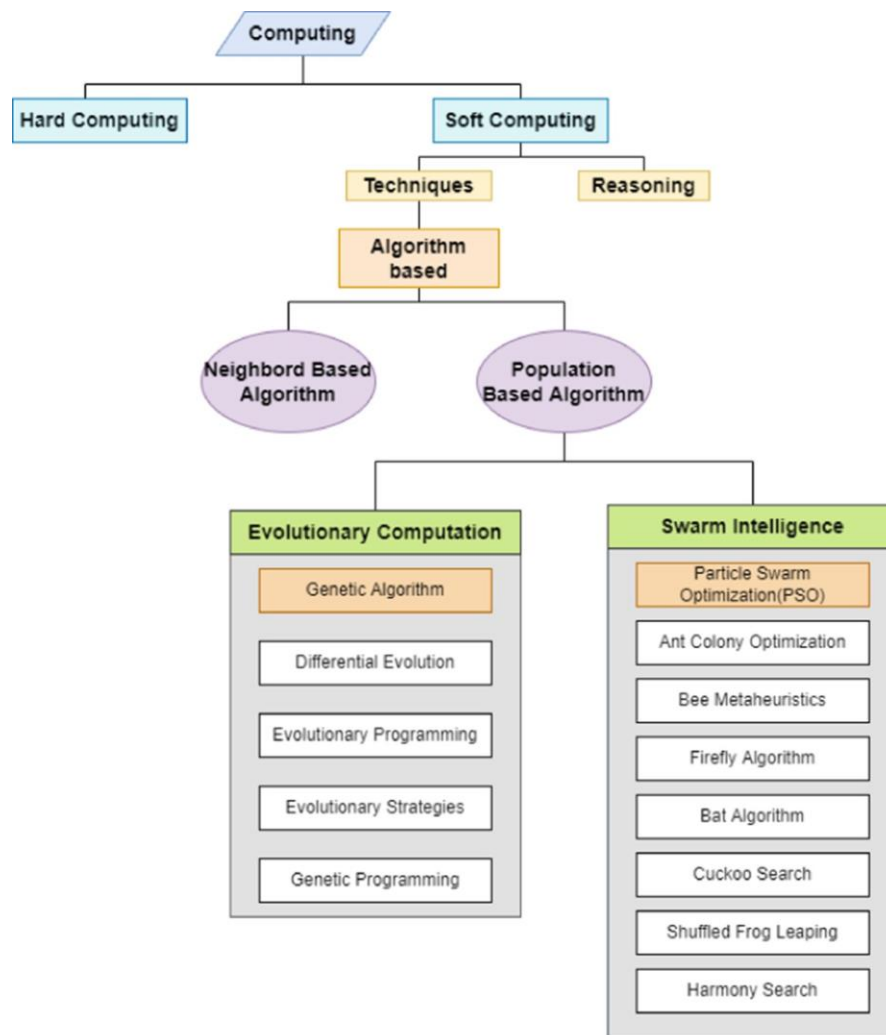


Fig. 1. Part of the classification of the heuristic algorithms by Kumar and Yavar [6].

“swarm intelligence” type have a greater presence with a total of 13 items. Within these articles, specific algorithms such as PSO, ACO, HS, etc., are applied.

In the research sub-question 1: What were the objectives of the water allocation optimization problems in the river basin? The articles reviewed had different objectives, however, the difference is that certain articles had the objective of testing or validating a novel hybrid algorithm, while other studies had the objective of solving the optimization problem without giving priority to the algorithm. Another of the objectives found is the focus on the reservoirs, but it should be emphasized that the study did not focus only on the reservoirs, however, it does present greater interest in these rather than the rest of the variables to be considered within the problem.




Fig. 2. Histogram of the heuristic methods used in the reviewed articles.

For example, [7] aims to find optimal values for a large number of water discharges in the network links (rivers and canals) and nodes (reservoirs and demands) while also looking for the optimal values of reservoir capacities and their storage priorities.

Another objective to highlight is the emphasis on social aspects. This is the case of [8], which proposes a socioeconomic model with two objectives. The first one is to maximize economic profitability and maximize employment. In the second objective the influence of water distribution on social welfare is considered. Other studies [2, 8–11] also have a social approach when considering the allocation of water to meet the population’s demand for water without considering whether there is economic benefit or not.

It is also considered an important objective to seek an ecological balance when allocating water. This is the case in studies [9, 11–14]. For example, in [14] the objective is summarized in minimizing water scarcity and the amount of contaminated water, but it also seeks to maximize economic interests including the generation of hydroelectric power. The other articles also presented several objectives, but they considered ecological balance important.

Several articles also mention the importance of agricultural areas [2, 8, 9, 12, 15–17]. For example, in [17] there is a focus on water allocation for irrigation that is compatible with climate change conditions in the Borkhar Plain in Iran.

In research sub-question 2: What tools or solvers are used to solve optimization models? Some of the articles decided to incorporate the heuristic methods with simulation models such as WEAP (water assessment and planning software) [12, 16] or MODSIM (software based on network flow programming) [17, 18]. The execution of heuristic algorithms can be done with MATLAB [2] or by programming with languages such as python. The articles do not specify in detail what software tools were used for the programming and/or execution of the algorithms, they only present the results.

In research sub-question 3: What parts are involved in the optimization process? The steps carried out in [8] encompasses the steps to follow in a study starting with data collection. In addition, it considers the distribution of

water in the agricultural, industrial and human consumption area, with the incorporation of social and economic criteria. The parts involved are summarized in: Data collection, preparation of the optimization model and implementation of the model. In the data collection is contemplated the water sources, necessary statistics (economic, population, etc.) and existing data on water resources. When preparing the optimization model, the decision variables, objectives and restrictions must be defined. For the implementation part, the execution of the optimization model is included as well as the analysis of the results based on what is indicated in the objectives of the study.

In the research sub-question 4: What indicators are used to analyze or validate the results of the optimization model? Two general forms of validation of results can be observed. The first way is to compare the developed meta-heuristic model with another heuristic model [2,11,19,20]. The second way is to analyze the Pareto front and consider the different trade-offs between the objectives [2, 9, 10, 12, 14, 16]. Comparisons are also made with the current situation, as is the case of [8], where the PSO algorithm gave results that produced a growth of 38% in economic benefits and profitability in the agricultural sector, a growth of 86% in the industrial sector and overall economic growth of 54% relative to current condition.

The results of the systematic review have revealed the main characteristics of two families of recurrent optimization methods, such as algorithms based on evolution and algorithms based on population intelligence. Furthermore, it is highlighted that these methods could work alone or be combined with other optimization processes, simulation techniques or meta-models to improve model performance.

In addition to minimizing water scarcity in demand areas for human consumption, there is also interest in distributing water in industrial and agricultural areas. These areas not only produce goods such as food but can also be a job generator and produce economic benefit to the region. Another interest is how the allocation of water can affect the environment and also how to comply with the ecological well-being of the region. The area that appears most in the revised bibliography is the socioeconomic part. This area is large and encompasses social aspects such as the right to access to drinking water as well as the reduction of costs (costs in reservoirs, agricultural production that will give more income, industrial production that brings economic income and also a source of job, etc.). These areas can present conflicts. For example, to increase the economic benefit in an area such as the industrial one, the amount of water in the agricultural area can be restricted.

The articles found for this literature review have simulation-optimization approaches, multi-objective optimization, improvements of classical algorithms, or construction of hybrid algorithms. In this study context, simulation-optimization models refer to the process of incorporating a meta-heuristic algorithm into a simulation model. For example, in [16] this approach is used. WEAP is the simulation model, which consists of a water evaluation and planning software that optimizes water distribution decisions using linear programs [12]. But water distribution optimization problems are usually nonlinear on a large scale, so it is possible to integrate this WEAP system with the meta-heuristic algorithm to optimize the problem. In this way, the general framework consists of defining the objective functions, executing the meta-heuristic algorithm and determining if the objective was met using the simulation (WEAP) to evaluate the objective functions with the values found by the meta-heuristic algorithm.

Another term to mention is multi-objective optimization. In order to understand the concept, is necessary to emphasize that there are different approaches for handling constraints in evolutionary algorithms [21], which include: penalty functions, repair operators or local search, modified matching/mutation operators that preserve constraints, and multi-objective formulations where constraints are reformulated as objectives. Multiobjective optimization seeks to approximate Pareto optimal trade-offs between conflicting objectives. These trade-offs are made up of the set of solutions that are better than all other solutions in at least one objective and are called non-dominated or Pareto optimal solutions [22]. A strength of multi-objective optimization is its ability to quickly approximate the true Pareto surface, even if it is not exactly quantified [21].

Starting with the classical PSO algorithm, which is based on the social behavior of flocks of birds to search through multidimensional dimension spaces, it has been widely used in the optimization of water resource systems [16] and it is also one of the most recurrent algorithms within this systematic review (table). This algorithm has been applied in conjunction with the multi-objective and simulation-optimization approach. In [16] both approaches are used generating a MOPSO-WEAP model to analyze the effectiveness of a water distribution project. In this case WEAP is the simulation model while MOPSO is the heuristic goal. Two objective functions were defined which were to minimize the sizes of the project infrastructures and to maximize the reliability of the water supply to the agricultural

lands. The results of applying optimization-simulation with PSO (MOPSO-WEAP) indicated that the project can meet these objectives.

Another study that uses the simulation-optimization technique is the one carried out in [17], which in this case uses MODSIM (based on network flow programming) as a simulation model and it is combined with the optimization algorithm Gray Wolf (GWO – Gray Wolf Optimization) to obtain the optimal amounts of irrigation and crop areas in the plain under two conditions: status quo, and with flows affected by climate change. The studied basin is the Zayandehroud basin, first its network is elaborated in the MODSIM model and the information related to each node is entered based on the data measured in the meteorological and hydrometric stations. The objective function of the model is to maximize profits from crop production and plan the optimal distribution of water.

Continuing with the line of studies where simulation and optimization are applied, is the one carried out in [18]. This study affirms that the simulation system would avoid having variables, functions, relationships, among others, and also achieve a continuous system. But the meta heuristic must evaluate the objective function on this simulation, which becomes computationally intensive. For this they propose the meta-model, which is used to produce computationally efficient substitutes for high-fidelity models. The most common are ANN, SVM, kriging and polynomial functions, which are evaluated in a water allocation problem based on surrogate optimization in the Atrak river basin in Iran. The simulation model used is MODSIM, which is a tool that allows analyzing the operation of river systems as networks of nodes and segments. While the applied heuristic goal is PSO. As conclusions, they determine that the ANN and SVM metamodels work better than others by saving the cost of evaluating the objective functions on the original model.

Another approach used is algorithm improvement. The study carried out by [23] uses a metaheuristic algorithm based on PSO, the Whale Optimization Algorithm (WOA). And on this algorithm, it uses an improvement (AWOA) to obtain a higher rate of convergence and precision. The aim of this study is to test the improvement versus traditional WOA and PSO algorithms for multi-objective water resource allocation resolution. In this case, the AWOA results indicate that there is higher convergence accuracy.

Hybrid algorithms are also presented, as is the case of [19], which integrates the weed optimization algorithm (WOA) and the particle swarm optimization algorithm (PSO), calling this hybrid WOAPSO. This algorithm is validated on two case studies, the first case study consists of an example of a river basin with 10 reservoirs, while the second is a hydropower optimization problem of three reservoirs in the Karoon river basin in Iran, which maximizes the efficiency index of hydroelectric power production. The results are compared with those obtained by the traditional algorithms of linear programming (LP), non-linear programming (NLP), WOA (in this case it is the weed algorithm - Weed Optimization Algorithm) and PSO; where WOAPSO proved to be more reliable in solving complex multi-reservoir systems in the context of integrated river basin management than classical optimization algorithms.

The next algorithm with the greatest presence is the genetic algorithm and its extensions. In [12] a Multi-Objective Optimization Genetic Algorithm (MOGA) is linked to Water Assessment and Planning (WEAP) software to optimize water allocation decisions over multiple years. The study region is Sistán, which is characterized as an arid zone, where the design variables of the problem consist of the cultivated area, the cultivation pattern and the wetland influx requirements for 30 years. The objective is to maximize the long-term net economic benefit and maximize the flow of water to the wetland. These objectives are incompatible between them, but the approach adopted in this study allows to obtain results that are analyzed by comparing purely economic scenarios versus multi-objective scenarios in the Pareto front. The authors also provide a description of the trade-offs in these scenarios to aid in the decision process for water resource stakeholders.

There is also the use of ant colonies (ACO) as an inspiration algorithm, which is a discrete combinatorial optimization algorithm based on the collective behavior of ants in their search for food. The literature review by [24] mentions that there are different versions of ACO that have proven to be flexible and powerful in solving a series of spatially and temporally complex water resource problems in discrete and continuous domains with unique objectives and/or multiple. One of the articles to highlight within this review is [13], which presents a multi-objective optimization framework with ACO to develop optimal trade-offs between water allocation and ecological benefit over a stretch of the Murray River in the South Australia. The results indicate that limited additional ecological benefit can be obtained as the allocation increases, by relaxing the flow constraints of the system. Additionally, the use of regulators can increase ecological benefits by using less water.

As indicated in the answer to question 4 of this systematic review, the majority of the authors of the reviewed articles include an analysis of the results. The analysis can be a comparison between optimization methods, or Pareto front analysis. It is also considered whether the algorithms can converge to an answer and the time taken. Another recurring analysis is the benefit obtained by optimizing the allocation of water and how much water was allocated to each demand node. Although not all the articles found are mentioned in detail, it can be seen that there is a strong inclination towards multiobjective methods and simulation-optimization. The improvement of classic algorithms or a mixture of algorithms to obtain new heuristics is also highlighted. Water resource management optimization problems in general are complex problems to be solved that depend on the number of variables to be considered, the objectives, the restrictions and the desired approach. Therefore, using improved metaheuristic, multi-objective and simulation-optimization methods turns out to be the best option for these problems. Another aspect to consider is the strong presence of PSO-based algorithms, since it offers a number of variants, as well as the flexibility to incorporate it with decision systems such as WEAP.

Conclusions

Although not all the articles found are mentioned in detail, it can be seen that there is a strong inclination towards multi-objective methods and simulation-optimization. The improvement of classic algorithms or the use of hybrid algorithms is also highlighted. Water resource management optimization problems in general are complex problems to be solved that depend on the number of variables to be considered, the objectives, the restrictions and the desired approach. Therefore, using improved meta-heuristic, multiobjective and simulation-optimization methods turns out to be the best option for these problems. In order to answer the main research question about which heuristic or metaheuristic methods have been applied in water allocation optimization problems in a river system with reservoirs, it has been found that each author decided to use the method that best adapted to their needs. However, it is necessary to mention that there is a strong presence of PSO-based algorithms, since it offers a number of variants, as well as the flexibility to incorporate it with decision systems such as WEAP.

Both PSO and the others algorithms mentioned in this review have their limitations. In the study carried out in [6], the advantages and disadvantages of some meta-heuristic algorithms in water resources problems, including PSO, are summarized. For PSO's family of algorithms, [6] mentions that the advantage of this type of algorithm is that they are simple to code and provide fast convergence, also implying a low computational cost. As a disadvantage, it is necessary to adjust parameters such as inertial weight, social and cognitive parameters. However, if the parameters are set correctly, the algorithm can achieve a global solution.

This systematic review aims to facilitate decision making on optimization models that can be used in water allocation optimization problems in a river system with reservoirs, considering the effectiveness and efficiency that these had when applied in real scenarios.

References

1. Liu, D., et al.: Optimisation of water-energy nexus based on its diagram in cascade reservoir system. *J. Hydrol.* **569** (2018). <https://doi.org/10.1016/j.jhydrol.2018.12.010>
2. Yang, Y., Luo, Q., Ye, G.: Optimization of water allocation system at the river basins. In: 2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), Huangshan, China, pp. 482–488, July 2018. <https://doi.org/10.1109/FSKD.2018.8687202>
3. Labadie, J.W.: Optimal operation of multi reservoir systems: state-of-the-art review. *J. Water Resour. Plann. Manag.* **130**, 93–111 (2004)
4. Janga Reddy, M., Nagesh Kumar, D.: Evolutionary algorithms, swarm intelligence methods, and their applications in water resources engineering: a state-of-the-art review. *H2Open J.* **3**(1), 135–188 (2020). <https://doi.org/10.2166/h2oj.2020.128>
5. Fink, A.: *Conducting Research Literature Reviews: From the Internet to Paper*. Sage, Thousand Oaks (2013)
6. Kumar, V., Yadav, S.M.: A state-of-the-art review of heuristic and metaheuristic optimization [techniques for the management of water resources](https://doi.org/10.2166/ws.2022.010). *Water Supply* (2022). <https://doi.org/10.2166/ws.2022.010>

7. Shourian, M., Mousavi, S.J.: Performance assessment of a coupled particle swarm optimization and network flow programming model for optimum water allocation. *Water Resour. Manag.* **31**(15), 4835–4853 (2017). <https://doi.org/10.1007/s11269-017-1781-8>
8. Habibi Davijani, M., Banihabib, M.E., Nadjafzadeh Anvar, A., Hashemi, S.R.: Multi-objective optimization model for the allocation of water resources in arid regions based on the maximization of socioeconomic efficiency. *Water Resour. Manag.* **30**(3), 927–946 (2016). <https://doi.org/10.1007/s11269-015-1200-y>
9. Babamiri, O., Azari, A., Maro, S.: An integrated fuzzy optimization and simulation method for optimal quality-quantity operation of reservoir-river system, p. 23 (2022)
10. Kazemi, M., Bozorg-Haddad, O., Fallah-Mehdipour, E., Loáiciga, H.A.: Inter-basin hydropolitics for optimal water resources allocation. *Environ. Monit. Assess.* **192**(7), 478 (2020). <https://doi.org/10.1007/s10661-020-08439-3>
11. Qu, G., Lou, Z.: Application of particle swarm algorithm in the optimal allocation of regional water resources based on immune evolutionary algorithm. *J. Shanghai Jiaotong Univ. (Sci.)* **18**(5), 634–640 (2013). <https://doi.org/10.1007/s12204-013-1442-x>
12. Farrokhzadeh, S., Hashemi Monfared, S., Azizyan, G., Sardar Shahraiki, A., Ertsen, M., Abraham, E.: Sustainable water resources management in an arid area using a coupled optimization-simulation modeling. *Water* **12**(3), 885 (2020). <https://doi.org/10.3390/w12030885>
13. Szemis, J.M., Dandy, G.C., Maier, H.R.: A multiobjective ant colony optimization approach for scheduling environmental flow management alternatives with application to the River Murray, Australia: multiobjective approach for environmental flow management. *Water Resour. Res.* **49**(10), 6393–6411 (2013). <https://doi.org/10.1002/wrcr.20518>
14. Liu, D., et al.: A macro-evolutionary multi-objective immune algorithm with application to optimal allocation of water resources in Dongjiang River basins, South China. *Stoch Environ. Res. Risk Assess.* **26**(4), 491–507 (2012). <https://doi.org/10.1007/s00477-011-0505-5>
15. Ashrafi, S.M., Dariane, A.: A novel and effective algorithm for numerical optimization: Melody Search (MS), pp. 109–114, December 2011. <https://doi.org/10.1109/HIS.2011.6122089>
16. Jamshid Mousavi, S., Anzab, N.R., Asl-Rousta, B., Kim, J.H.: Multi-objective optimization simulation for reliability-based inter-basin water allocation. *Water Resour. Manag.* **31**(11), 3445–3464 (2017). <https://doi.org/10.1007/s11269-017-1678-6>
17. Jamshidpey, A., Shourian, M.: Crop pattern planning and irrigation water allocation compatible with climate change using a coupled network flow programming-heuristic optimization model. *Hydro. Sci. J.* **66**(1), 90–103 (2021). <https://doi.org/10.1080/02626667.2020.1844889>
18. Mirfenderesgi, G., Mousavi, S.J.: Adaptive meta-modeling-based simulation optimization in basin-scale optimum water allocation: a comparative analysis of meta-models. *J. Hydroinf.* **18**(3), 446–465 (2016). <https://doi.org/10.2166/hydro.2015.157>
19. Asgari, H.-R., Bozorg-Haddad, O., Soltani, A., Loáiciga, H.A.: Optimization model for integrated river basin management with the hybrid WOAPSO algorithm. *J. Hydro-Environ. Res.* **25**, 61–74 (2019). <https://doi.org/10.1016/j.jher.2019.07.002>
20. Fang, G., et al.: Multi-objective differential evolution-chaos shuffled frog leaping algorithm for water resources system optimization. *Water Resour. Manag.* **32**(12), 3835–3852 (2018). <https://doi.org/10.1007/s11269-018-2021-6>
21. Nicklow, J., et al.: State of the art for genetic algorithms and beyond in water resources [planning and management. *J. Water Resour. Plann. Manag.* **136**\(4\), 412–432 \(2010\). \[https://doi.org/10.1061/\\(ASCE\\)WR.1943-5452.0000053\]\(https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000053\)](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000053)
22. Pareto, V.: *Cours D'Economie Politique*. Rouge, Lausanne (1896)
23. Yan, Z., Sha, J., Liu, B., Tian, W., Lu, J.: An ameliorative whale optimization algorithm for multi-objective optimal allocation of water resources in Handan, China. *Water* **10**(1), 87 (2018). <https://doi.org/10.3390/w10010087>
24. Afshar, A., Massoumi, F., Afshar, A., Mariño, M.A.: State of the art review of ant colony optimization applications in water resource management. *Water Resour. Manag.* **29**(11), 3891–3904 (2015). <https://doi.org/10.1007/s11269-015-1016-9>

Anexo C: Implementación en Pymoo para PSO.

Para la implementación en Pymoo se construye matrices de $N \times D$, donde N es el número de iteraciones y D , el número de variables o dimensión del problema. En cada fase de calibración, validación e implementación esta dimensión va a variar ya que las variables se distinguen por

que representan dentro del problema y también por el salto de tiempo en el que están. Si una variable representa la cantidad de agua en el reservorio, hay 60 variables distintas que representan la cantidad de agua en el reservorio de cada día dentro de dos meses. Para poder implementar las funciones objetivo y las restricciones se genera primero archivos que mantienen el tracking de las posiciones de las variables en cada salto de tiempo y construir las restricciones y calcular la función objetivo.

Una vez guardada la información de las posiciones se construye una clase hija de “ElementwiseProblem”, que es una clase propia de Pymoo que permite agregar restricciones de igualdad, desigualdad y la función objetivo. También permite utilizar hilos de ejecución de Python y enviar funciones del tipo Repair para intentar disminuir el número de restricciones violadas por los valores originales encontrados por PSO y mover las partículas a una zona donde cumplan con más restricciones.

Se utiliza PostgreSQL como base de datos para leer la información de la serie de tiempo construida por ArcSWAT.

En <https://github.com/berenice1997/Guerrero-PSO-code.git> se puede acceder al código fuente usado para la implementación del problema.