


Maestría en Ingeniería Civil

**IDENTIFICACIÓN DE REGLAS DE OPERACIÓN ÓPTIMAS DE
EMBALSES PARA EL CONTROL DE INUNDACIONES A PARTIR
DE MODELOS DE OPERACIÓN. CASO DE ESTUDIO: CUENCA
DEL RÍO YUNA EN REPÚBLICA DOMINICANA**

Carlos Alfredo Tami Riveros

Bogotá, D.C., 5 de noviembre de 2020



**IDENTIFICACIÓN DE REGLAS DE OPERACIÓN ÓPTIMAS DE
EMBALSES PARA EL CONTROL DE INUNDACIONES A PARTIR
DE MODELOS DE OPERACIÓN. CASO DE ESTUDIO: CUENCA
DEL RÍO YUNA EN REPÚBLICA DOMINICANA**

**Tesis para optar al título de magíster en Ingeniería Civil, con
énfasis en recursos hidráulicos y medio ambiente**


Ph. D. Germán Ricardo Santos Granados

Director

Ph. D. Gerald Augusto Corzo Pérez

Co-director

Bogotá, D.C., 5 de noviembre de 2020



La tesis de maestría titulada “Identificación de reglas de operación óptimas de embalses para el control de inundaciones a partir de modelos de operación. Caso de estudio: Cuenca del río Yuna en República Dominicana”, presentada por Carlos Alfredo Tami Riveros, cumple con los requisitos establecidos para optar al título de Magíster en Ingeniería Civil con énfasis en recurso hidráulicos y medio ambiente.

Director de la tesis

Germán Ricardo Santos Granados

Co-Director

Gerald Augusto Corzo Pérez

Jurado

José Fidel Pérez

Bogotá, D.C., 5 de noviembre de 2020

Dedicatoria

Dedico este trabajo a mi familia, quienes con su apoyo incondicional me motivan constantemente a alcanzar mis metas.

Agradecimientos

Agradezco a la Escuela Colombiana de Ingeniería por la oportunidad de formación académica y crecimiento intelectual. Al Doctor Germán Santos por su tiempo y los conocimientos compartidos para el desarrollo de este trabajo.

Agradezco al Doctor Gerald Corzo por toda su guía y enseñanzas brindadas para la realización de este proyecto.

También agradezco al Doctor Fidel Pérez, por toda la información suministrada y aportes en el presente trabajo.

Resumen

El presente estudio aborda el uso de herramientas computacionales con el fin de obtener reglas de operación óptimas para el embalse de Hatillo (República Dominicana), considerando principalmente el propósito de disminuir inundaciones aguas abajo de la presa sin afectar los demás usos del mismo (generación hidroeléctrica y el riego para la agricultura). Debido a que es un embalse multipropósito, el problema es planteado bajo un enfoque multiobjetivo, donde se explora el uso de algoritmos evolucionarios (optimizadores), junto con funciones de aproximación de Redes Neuronales artificiales, Redes de base radial y funciones lineales (Modelos de operación paramétricos) para la búsqueda directa de las reglas de operación obtenidas de los Frentes de Pareto generados. Los modelos de operación propuestos se desarrollaron para la información disponible que comprende un periodo de 10 años (2009-2019), a nivel diario, las descargas controladas del embalse fueron definidas a partir de las funciones de aproximación, las cuales reciben como entradas las variables de estado del sistema (nivel del embalse, caudales de entrada, descargas previas), así mismo, se utilizan componentes físicos propios del sistema para definir las restricciones de las descargas controladas, límites de operación del embalse, y para definir las descargas no controladas (rebose por el vertedero). Sobre los modelos de operación se aplicaron los algoritmos de optimización para la obtención de las reglas de operación óptimas, siendo los parámetros de las funciones de aproximación las variables de decisión de cada modelo. Los algoritmos de optimización utilizados fueron el Non-dominated Sorting Genetic Algorithm II (NSGA-II) y Multiobjective Evolutionary Algorithm Based on Decomposition (MOEA/D), el proceso anterior fue realizado en JMETALPY un entorno de optimización multiobjetivo desarrollado en Python.

Los resultados obtenidos muestran que es posible reducir los picos de los hidrogramas de descarga del embalse y por ende la magnitud de las inundaciones aguas abajo de la presa aplicando las reglas de operación obtenidas de la optimización de los modelos de operación. Para este caso en particular se encontró que las funciones de aproximación de Redes Neuronales y Redes de Base Radial permiten parametrizar adecuadamente las reglas de operación del embalse ya que pueden generar patrones o formas complejas que normalmente no pueden ser construidas por otras funciones, como, por ejemplo, funciones lineales. Los resultados de la optimización demuestran que las Redes Neuronales artificiales se ajustan mejor respecto a los otros métodos para este caso de estudio, siendo el NSGAI el algoritmo de optimización que mejor desempeño tiene en términos de tiempo computacional y resultados de optimización.

Tabla de contenido

Resumen.....	6
1. Introducción.....	16
1.1 Planteamiento del problema	16
1.2 Objetivos	19
1.2.1 Objetivo general.	19
1.2.2 Objetivos específicos.....	19
1.3 Organización del documento	19
2. Revisión de la literatura	21
2.1 Optimización en la gestión de embalses.....	21
2.2 Algoritmos, Funciones de aproximación y entornos de desarrollo.....	26
2.2.1 Algoritmos de optimización	26
2.2.2 JMETALPY	32
2.2.3 Funciones de aproximación	33
3. Metodología de la investigación.....	39
3.1 Análisis del sistema.....	39
3.1.1 Análisis de información.....	40
3.1.2 Identificación de las reglas de operación actuales del sistema	40
3.1.3 Definición de objetivos del sistema	41
3.2 Construcción de los modelos de operación	42
3.3 Obtención de frentes de Pareto (optimización)	43
3.4 Obtención de las reglas de operación óptimas	44
4. Caso de estudio.....	46
4.1 Área de estudio	46
4.1.1 Cuenca del Río Yuna.....	46
4.1.2 Embalse de Hatillo.....	51

4.2	Descripción específica del problema	52
4.3	Recolección de Datos y Procesamiento.....	54
4.4	Aplicación de la metodología de la investigación	56
4.4.1	Análisis del sistema	56
4.4.2	Identificación de las reglas de operación actuales del embalse	62
4.4.3	Modelos de operación	66
4.4.4	Estimación de la demanda de agua para riego	76
4.4.5	Cálculo de la potencia generada por turbinado.....	80
4.4.6	Optimización	81
4.4.7	Selección del mejor frente de Pareto	86
4.4.8	Obtención de las reglas de operación óptimas	88
5	Resultados y contribuciones	94
5.1	Frentes de Pareto.....	94
5.1.1	Modelos de operación con RNA usando NSGAI.....	94
5.1.2	Modelos de operación con RBR usando NSGAI.....	100
5.1.3	Modelos de operación con función lineal NSGAI	107
5.1.4	Modelos de operación con RNA MOEA/D	112
5.1.5	Modelos de operación con función lineal MOEA/D	117
5.1.6	Comparación de resultados	121
5.1.7	Selección de reglas de operación	125
5.1.8	Validación de resultados.....	136
6	CONCLUSIONES Y RECOMENDACIONES	138
	Bibliografía.....	140

Índice de tablas

Tabla 1. Eventos de inundaciones en el Bajo Yuna en los últimos 11 años.	54
Tabla 2. Indicadores de MSE y MAE para las diferentes configuraciones de RNA evaluadas	65
Tabla 3. Demanda de agua para riego Bajo Yuna, embalse de Hatillo.	80
Tabla 4. Parámetros de los algoritmos de optimización NSGAI y MOEA/D.....	86
Tabla 5. Mejores soluciones para cada uno de los objetivos de los modelos con RNA y el algoritmo NSGAI.....	96
Tabla 6. Mejores soluciones para cada uno de los objetivos de los modelos con RBR y el algoritmo NSGAI.....	103
Tabla 7. Mejores soluciones para cada uno de los objetivos de los modelos con función lineal y el algoritmo NSGAI.	108
Tabla 8. Mejores soluciones para cada uno de los objetivos de los modelos con RNA y el algoritmo MOEA/D.....	114
Tabla 9. Mejores soluciones para cada uno de los objetivos de los modelos con función lineal y el algoritmo MOEA/D.	118
Tabla 10. Valores de hipervolumen obtenidos para los diferentes modelos e operación.	123
Tabla 11. Evaluación de las reglas de operación seleccionadas en la reducción de caudales pico para los eventos extremos FO1 vs FO2.	128
Tabla 12. Evaluación de las reglas de operación seleccionadas en la reducción de caudales pico para los eventos extremos FO1 vs FO3.	132
Tabla 13. Evaluación de las reglas de operación seleccionadas en la reducción de caudales pico para los eventos extremos. Serie sintética.	137

Índice de figuras

Figura 1. Metodologías para la optimización de embalses	24
Figura 2. Flujograma para la aplicación de Algoritmos Genéticos	28
Figura 3. Flujograma del algoritmo NSGAII.....	30
Figura 4. Diagrama esquemático del mecanismo de promoción de individuos del NSGA-II	30
Figura 5. Flujograma del algoritmo MOEA/D.....	32
Figura 6. Flujograma del entorno JMETALPY	33
Figura 7. Esquema general de la arquitectura de una Red Neuronal Artificial.....	35
Figura 8. Operación interna en las neuronas de la Red Neuronal Artificial.....	35
Figura 9. Esquema general de la arquitectura de una Red de Base Radial	37
Figura 10. Flujograma de la metodología de investigación	39
Figura 11. Flujograma optimizador JMETALPY	44
Figura 12. Localización general de la Cuenca del Río Yuna	47
Figura 13. Cuenca Río Yuna: (a) Localización y componentes Cuenca Río Yuna, (b) Modelo de elevación digital Cuenca Río Yuna.	48
Figura 14. Área regulada por embalses en la Cuenca del Río Yuna	49
Figura 15. Mapa de precipitaciones medias mensuales en la Cuenca del Río Yuna.....	50
Figura 16. Área de regulación embalse de Hatillo.....	51
Figura 17. Componentes del embalse de Hatillo. Vista en planta de los componentes de la Presa. (b) Niveles de operación.	52
Figura 18. Planicie de inundación en el Bajo Yuna	53
Figura 19. Caudales de entrada y de salida del embalse de Hatillo para el periodo 2009-2019.	55
Figura 20. Batimetría embalse de Hatillo (Nivel vs Volumen).....	55
Figura 21. Niveles del embalse de Hatillo para el periodo 2009 - 2019.....	56
Figura 22. Análisis de correlación entre caudales de entrada vs caudales de salida; Niveles vs Caudales de salida; y Autocorrelación del caudal de salida	58
Figura 23. Superficie de correlación entre Caudal de salida y caudal de entrada para diferentes rangos de caudales de salida del embalse y diferentes retardos (Lags).....	59
Figura 24. Superficie de correlación entre Caudal de salida y Niveles del embalse para diferentes rangos de caudales de salida del embalse y diferentes retardos.....	60

Figura 25. Autocorrelación de los caudales de salida del embalse para un lag de 10 días y para diferentes rangos de caudales	61
Figura 26. Configuración final de RNA para las reglas de operación actuales del embalse	65
Figura 27. Hidrograma de caudales de descarga del embalse obtenido para el test de validación del modelo final de RNA de 7 Neuronas	66
Figura 28. Evaporación media mensual multianual para la zona de estudio.	69
Figura 29. Relación Nivel vs Superficie del embalse de Hatillo.	70
Figura 30. Flujograma de los modelos de operación construidos para el embalse de Hatillo.	71
Figura 31. Configuración de las RNA propuestas para los modelos de operación.	73
Figura 32. Configuración de las RBR para modelos de operación.	75
Figura 33. Modelos de operación propuestos para el embalse de Hatillo.....	76
Figura 34. Área de cultivos alimentados por Hatillo en la zona del Bajo Yuna.	78
Figura 35. Imagen Satelital del Área de cultivos en la zona del Bajo Yuna.	78
Figura 36. Eficiencia de las turbinas en función del caudal de flujo.....	81
Figura 37. introducción de problemas de optimización al entorno JMETALPY	82
Figura 38. Esquema Espacio de Pareto tridimensional	87
Figura 39. Espacio de Pareto que iguala o mejora las reglas de operación actual.....	88
Figura 40. Superficies de modelo hidráulico Cuenca baja Río Yuna	90
Figura 41. Malla para el modelo hidráulico Cuenca baja Río Yuna	90
Figura 42. Componentes para la elaboración de la serie de caudales de entrada sintéticos.....	92
Figura 43. Serie sintética de caudales de entrada para el embalse de Hatillo.....	93
Figura 44. Frentes de Pareto para modelos con RNA usando el algoritmo NSGAI (a) Frente Pareto RNA 7N, (b) Frente Pareto RNA 6N, (c) Frente Pareto RNA 4N, (d) Frente de Pareto combinado para los 3 modelos RNA	95
Figura 45. Frentes de Pareto 2D para modelos con RNA usando el algoritmo NSGAI. (a) FO1 vs FO3; (b) FO2 vs FO3; (c) FO1 vs FO2	96
Figura 46. Hidrogramas de descarga del embalse para los modelos optimizados de RNA.....	98
Figura 47. Comparación de los objetivos para las reglas de operación obtenidas usando RNA.....	99

Figura 48. Simulación de Reglas de operación optimizadas usando RNA para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación.....	100
Figura 49. Frentes de Pareto para modelos con RBR usando el algoritmo NSGAI (a) Frente Pareto RBR 7B, (b) Frente Pareto RBR 6B, (c) Frente Pareto RBR 4B, (d) Frente de Pareto combinado para los 3 modelos RBR.....	101
Figura 50. Frentes de Pareto 2D para modelos con RBR usando el algoritmo NSGAI (a) FO1 vs FO3, (b) FO2 vs FO, (c) FO1 vs FO2	102
Figura 51. Hidrogramas de descarga del embalse para los modelos optimizados de RBR.....	104
Figura 52. Comparación de los objetivos para las reglas de operación obtenidas usando RBR.....	105
Figura 53. Simulación de Reglas de operación optimizadas usando RBR para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.	106
Figura 54. Frente de Pareto 3D para modelo de operación con función Lineal	107
Figura 55. Frentes de Pareto para modelos de operación con FL (a) FO1 vs FO3, (b) FO2 vs FO3, (c) FO1 vs FO2.....	108
Figura 56. Hidrogramas de descarga del embalse para los modelos optimizados de Función lineal..	110
Figura 57. Comparación de los objetivos para las reglas de operación obtenidas usando función lineal.....	111
Figura 58. Simulación de Reglas de operación optimizadas usando función lineal para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.	112
Figura 59. a) Frente Pareto RNA 7N, (b) Frente Pareto RNA 6N, (c) Frente Pareto RNA 4N, (d) Frente de Pareto combinado para los 3 modelos RNA. Utilizando MOEA/D.....	113
Figura 60. Frentes de Pareto para modelos de operación con RNA (a) FO1 vs FO3, (b) FO2 vs FO3, (c) FO1 vs FO2. Utilizando MOEA/D	114
Figura 61. Hidrogramas de descarga del embalse para los modelos optimizados de RNA usando MOEA/D.....	115

Figura 62. Comparación de los objetivos para las reglas de operación obtenidas usando RNA con el algoritmo MOEA/D	116
Figura 63. Simulación de Reglas de operación optimizadas usando RNA con el algoritmo MOEA/D para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.	116
Figura 64. Frente de Pareto 3D para modelo de operación con función Lineal usando el algoritmo MOEA/D.....	117
Figura 65. Frentes de Pareto para modelos de operación con FL usando el algoritmo MOEA/D; (a) FO1 vs FO3, (b) FO2 vs FO3, (c) FO1 vs FO2	118
Figura 66. Hidrogramas de descarga del embalse para los modelos optimizados con Función lineal y el algoritmo MOEA/D.....	119
Figura 67. Comparación de los objetivos para las reglas de operación obtenidas usando función lineal y el algoritmo MOEA/D.....	120
Figura 68. Simulación de Reglas de operación optimizadas usando función lineal y el algoritmo MOEA/D para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.	120
Figura 69. Frente de Pareto 3D unificado para todos los modelos de operación.....	121
Figura 70. Frente de Pareto 2D unificado para todos los modelos de operación FO1 vs FO3.....	122
Figura 71. Frente de Pareto 2D unificado para todos los modelos de operación FO1 vs FO2	122
Figura 72. Frente de Pareto 2D unificado para todos los modelos de operación FO2 vs FO3.....	123
Figura 73. Envolverte para hidrogramas generados por todas las reglas de operación obtenidas de la optimización.....	124
Figura 74. Envolverte para hidrogramas generados por todas las reglas de operación obtenidas de la optimización.....	124
Figura 75. Comparación de los objetivos para todas las reglas de operación	125
Figura 76. Acercamiento del frente de Pareto unificado FO1 vs FO2 para el espacio de decisión.	126

Figura 77. Hidrogramas de salida del embalse para las reglas de operación seleccionadas y la regla de operación actual.	127
Figura 78. Hidrogramas de salida del embalse para las reglas de operación seleccionadas del espacio (FO1 vs FO2) y la regla de operación actual durante el evento de enero de 2018	129
Figura 79. Acercamiento del frente de Pareto unificado FO1 vs FO3 para el espacio de decisión	130
Figura 80. Hidrogramas de salida del embalse para las reglas de operación seleccionadas del espacio (FO1 vs FO3) y la regla de operación actual durante el evento de enero de 2018	131
Figura 81. Hidrogramas de salida del embalse para las reglas de operación seleccionadas del espacio (FO1 vs FO2) y la regla de operación actual durante el evento de enero de 2018.	132
Figura 82. Simulación de Mancha de inundación con las reglas de operación actual del embalse para la ola invernal de abril de 2017	134
Figura 83. Simulación de Mancha de inundación con la regla de operación RN_7N_40 para la ola invernal de abril de 2017	134
Figura 84. Simulación de Mancha de inundación con la regla de operación RN_7N_40 (mancha roja) y con la regla de operación actual para la ola invernal de abril de 2017 aguas debajo del embalse.....	135
Figura 85. Hidrogramas de salida del embalse para las reglas de operación optimizadas y la regla de operación actual para el caudal pico más alto de la serie sintética.	136
Figura 86. Hidrogramas de salida del embalse para las reglas de operación optimizadas y la regla de operación actual para el caudal pico de la serie sintética	137

Índice de anexos

Anexo 1. Código Modelos de operación (Programación en Python)

145

1. Introducción

1.1 Planteamiento del problema

Las inundaciones que se registran cada año en el mundo producto de eventos hidrológicos extremos son causantes de grandes impactos socioeconómicos que representan un tercio del total de las catástrofes naturales en el planeta en cuanto a pérdidas económicas y al menos más de la mitad de las víctimas humanas en las mismas (Ceballos Bernal, Baró Suárez, & Díaz Delgado, 2016). Este panorama no es alentador si además se tiene en cuenta que el número de inundaciones ha incrementado en más de dos veces desde 1980 hasta la última década (Arreguín Cortés & Marengo Mogollón, 2016) como consecuencia entre otras cosas de problemas de ordenamiento territorial y los efectos que tiene el cambio climático sobre el ciclo hidrológico. En este contexto, cobra gran relevancia la necesidad de mejorar la eficiencia en la gestión de los sistemas de recursos hídricos existentes mediante el manejo óptimo de los embalses para reducir el impacto de estos eventos extremos.

La operación de un embalse, puede estar sujeta al cumplimiento de uno o varios objetivos, entre los que están el suministro de agua para una población, la irrigación, la generación de energía eléctrica o el control de inundaciones. De los embalses existentes en el mundo, los que operan con el único propósito de controlar inundaciones es menor respecto a los demás usos mencionados. Es más común encontrar embalses para irrigación y centrales hidroeléctricas (Foundation for Water Research, 2010). Sin embargo, en los embalses multipropósito existentes, el control de inundaciones es uno de los objetivos más comunes, especialmente en aquellos que tienen mayor capacidad de almacenamiento. Teniendo en cuenta la cantidad de intereses que pueden existir en la toma de decisiones para la operación de un embalse, encontrar un equilibrio o acuerdo entre las diferentes partes involucradas no es una tarea fácil. En el caso de los sistemas donde uno de los propósitos es el control de inundaciones, este entra en conflicto con la generación energética o el

suministro de agua. De allí entonces, la importancia de buscar políticas de operación óptimas para la gestión de embalses multipropósito.

Las políticas de operación de un embalse son el conjunto de reglas para determinar la cantidad de agua que se debe almacenar y descargar bajo diferentes condiciones o escenarios (Wurbs, 1993). Es decir, definen como se debe operar el embalse para cumplir con unos objetivos o propósitos específicos para el sistema. Generalmente, las reglas de operación son representadas mediante curvas de referencia, donde los caudales de descarga se definen en función del nivel de almacenamiento del embalse. Sin embargo, estas también pueden ser representadas mediante funciones matemáticas o parametrizaciones (Momtahan & Dariane, 2007), (Giuliani, Castelletti, Pianosi, Mason, & Reed, 2016). Teniendo en cuenta lo anterior, la optimización de un embalse es básicamente la búsqueda de las reglas de operación óptimas que permitan cumplir con los objetivos planteados de la mejor forma posible.

En las últimas décadas la optimización de embalses ha sido un tema que ha ganado el interés de muchos investigadores (Ritter, 2016), ya que su aplicación aporta considerables beneficios, ahorros y prolonga la utilidad de los embalses; en palabras de Labadie (2004), existen pocas áreas de aplicación de modelos de optimización con un historial más rico o más diverso que la optimización de embalses ya que el desarrollo de nuevos marcos y metodologías para definir reglas de operación ha permitido y permitirá un mejor uso a gran escala del agua disponible en las cuencas hídricas, produciendo así, mejoras sustanciales en su aprovechamiento.

En el presente estudio, se abordó el caso de la cuenca del Río Yuna en República Dominicana, la cual es una región que a lo largo de la historia ha sido afectada por fuertes inundaciones principalmente en su parte baja, donde se han registrado eventos como el de noviembre de 2007 (Tormenta tropical NOEL) o el de agosto de 2012 (Tormenta Tropical Isaac), que han generado grandes afectaciones socioeconómicas a la población. Esta cuenca está parcialmente regulada por los embalses de Hatillo, Rincón, y otros de menor tamaño localizados en la parte alta de la cuenca (Blanco y Tireo). Sin embargo, en cuanto a tamaño y capacidad Hatillo se destaca muy por encima de los demás, siendo el que controla, la mayor parte del área regulada de la cuenca. Este embalse tiene los propósitos de generar energía eléctrica, suministrar agua para riego, y controlar inundaciones en el

bajo Yuna. Si bien la operación de este embalse no está relacionada directamente con los problemas de inundaciones anteriormente mencionados, debido a la severidad de los eventos hidrológicos que las producen, surge la pregunta: ¿es posible reducir la magnitud de las inundaciones mediante un manejo óptimo del embalse sin afectar los demás propósitos?

Así entonces, se buscó la optimización del embalse de Hatillo haciendo énfasis en el propósito del control de inundaciones dado los problemas antes expuestos, sin embargo, por tratarse de un embalse multipropósito, este problema no podría haber sido abordado teniendo en cuenta un solo objetivo de operación, siendo indispensable analizar todos los propósitos bajo un enfoque multiobjetivo. En este contexto, se planteó el uso de los algoritmos NSGAI y MOEA/D, para la obtención de los frentes de Pareto que permitieron la identificación de las reglas de operación óptimas. La operación del embalse fue simulada mediante modelos de operación construidos a partir de funciones de aproximación como las Redes Neuronales Artificiales, Redes de Base Radial y funciones lineales, modelos sobre los que se aplicaron los algoritmos de optimización. En la literatura existente de la optimización de embalses son escasos los estudios que han empleado conjuntamente estos algoritmos de optimización multiobjetivo aplicado a diferentes modelos de operación construidos con funciones de aproximación, y menos considerando estos tres objetivos, por lo tanto, este estudio permitió evaluar el desempeño tanto de los algoritmos de optimización como de las funciones de aproximación mencionados aplicados a este tipo de embalses.

1.2 Objetivos

1.2.1 Objetivo general.

Definir reglas de operación óptimas para embalses que permitan reducir las inundaciones durante eventos hidrológicos extremos, aplicado al caso de estudio del embalse de Hatillo en República Dominicana.

1.2.2 Objetivos específicos.

- Analizar los componentes físicos e hidrológicos más importantes de la Cuenca del Río Yuna y del embalse de Hatillo.
- Identificar las reglas de operación que actualmente rigen en la operación del embalse de Hatillo.
- Construir modelos de operación para el embalse de Hatillo utilizando funciones matemáticas de aproximación y teniendo en cuenta los componentes físicos del sistema.
- Optimizar las reglas de operación de los modelos propuestos para el cumplimiento de las metas de suministro de agua, generación de energía y reducción de inundaciones aguas abajo.
- Modelar las reglas de operación propuestas y realizar su comparación con la operación actual del sistema.

1.3 Organización del documento

El presente trabajo está organizado de la siguiente manera:

En el capítulo 2, se presenta la revisión de la literatura, comenzando por el panorama general o el estado del arte de la optimización de embalses, hasta una descripción de los métodos computacionales empleados, algoritmos multiobjetivo, funciones de aproximación y librerías o ambientes de desarrollo empleados. Utilizando estos conocimientos como base, en el capítulo 3, se muestra paso a paso la metodología utilizada en la presente investigación. En el capítulo 4, se describe el caso de estudio, el cual corresponde al embalse de Hatillo en República Dominicana, donde, además, se aplica la metodología detallada en el capítulo 3, empezando por el análisis del sistema, para después realizar la construcción de los modelos de operación, obtener los frentes de Pareto y finalmente definir las reglas de operación óptimas.

Los resultados del presente estudio son mostrados a detalle en el capítulo 5, donde se muestran los frentes de Pareto obtenidos, las reglas de operación óptimas y la comparación entre los diferentes modelos y algoritmos empleados en la optimización. Para terminar, en el capítulo 6, se presentan las conclusiones del trabajo, en donde se comentan los resultados según los objetivos planteados y el valor práctico del presente estudio, así como propuestas para futuros trabajos en el tema.

2. Revisión de la literatura

En el presente capítulo se muestra el marco teórico empleado en esta investigación, comenzando por una revisión general del estado del arte en la optimización de embalses, mencionando los principales enfoques metodológicos que han sido utilizados históricamente para abordar este tipo de problemas y los modelos o técnicas más utilizadas. Posteriormente, se realiza la descripción de los métodos computacionales utilizados concretamente en este estudio, algoritmos multiobjetivo, funciones de aproximación, así como las librerías o ambientes de desarrollo empleados.

2.1 Optimización en la gestión de embalses

En las últimas décadas, la búsqueda de políticas de operación óptimas de embalses ha sido una de las áreas de mayor estudio dentro de los sistemas de recursos hidráulicos (Momtahan y Dariane, 2007).

Históricamente, las soluciones a problemas de optimización de embalses han sido abordadas bajo diferentes enfoques o metodologías desarrolladas por varios autores. Una de las más utilizadas es la optimización estocástica implícita (OEI), en la cual se utiliza inicialmente un modelo de optimización determinístico para encontrar los caudales óptimos de salida en cada paso de tiempo representándolos como un vector de resultados, posteriormente, mediante una función de regresión o un modelo de aprendizaje se obtienen las reglas de operación del embalse (como el utilizado por Raman & Chandramouli, 1996); este enfoque realiza la optimización a partir de series de caudales históricos de entrada. Dentro de estos enfoques están los modelos de Programación lineal (PL), en el cual el método Simplex es uno de los más utilizados; en esta técnica se requiere que todas las ecuaciones del problema sean lineales. Hiew (1987) por ejemplo, aplicó OEI utilizando PL para el proyecto Colorado-Big Thompson compuesto por ocho embalses, en el cual utilizó un historial de 30 años de caudales de entrada mensuales, resultando en un problema con

12613 variables y 5040 restricciones. Para producir las curvas de referencia óptimas (reglas de operación) utilizó un análisis de regresión lineal.

Así mismo, en muchos problemas de optimización de embalses principalmente en los que implican la producción de energía eléctrica, se han utilizado modelos de programación no lineal (PNL) debido a la complejidad de los patrones o modos de operación que éstos pueden llegar a tener. Uno de éstos modelos es la Programación Lineal Sucesiva (PLS) el cual ha sido aplicado ampliamente en hidroeléctricas como el desarrollado por Barros et al. (2003) para el sistema de Brasilia con resultados satisfactorios tanto en precisión como en eficiencia computacional.

Una de las técnicas de optimización más utilizadas junto con la programación lineal dentro del enfoque (OEI), ha sido la Programación dinámica (Yakowitz, 1982), en la cual se descompone el problema en subproblemas que se solucionan de forma secuencial en cada etapa o periodo de tiempo. Karamouz et al. (1992) aplicaron un modelo de programación dinámica discreta para un sistema de embalses múltiples en la cuenca del río Gunpowder cerca de Baltimore. Para este caso se utilizaron datos de caudales sintéticos con un total de 1500 meses, para la definición de las reglas de operación se utilizó una función de regresión lineal. Este método, sin embargo, aumenta su complejidad y presenta limitaciones en problemas que involucran sistemas de embalses de alta dimensionalidad (múltiples variables).

Otro de los enfoques o metodologías empleadas en los problemas de optimización de embalses es la optimización estocástica explícita (OEE), de la cual la programación dinámica estocástica (PDE) es quizá el modelo más representativo y uno de los que se usa con mayor frecuencia (p. ej. Butcher 1971; Torabi & Mobasheri 1974; Stedinger et al. 1984). Estos modelos funcionan sobre descripciones probabilísticas de variables aleatorias, en lugar de secuencias hidrológicas determinísticas, es decir, la optimización se realiza sin la presunción de un conocimiento perfecto previo de los eventos futuros (Labadie 2004). Además, las políticas de operación se determinan sin la necesidad de inferir reglas de operación desde los resultados de la optimización. Éstas técnicas, sin embargo, tienden a tener mayor costo computacional en problemas de alta dimensionalidad respecto a las metodologías OEI.

Con el avance en los recursos computacionales acompañado de mejores tecnologías y equipos más robustos, las técnicas metaheurísticas y modelos “Data driven” han ido ganando popularidad en el área de los sistemas de recursos hídricos. Por ejemplo, Sharif & Wardlaw (2000) propusieron algoritmos genéticos (AG), método basado en la ley de la selección Natural de Darwin, para la optimización directa de los caudales de descarga de embalses como alternativa a los enfoques de optimización determinísticos, los cuales requieren la discretización de las variables de estado (programación dinámica). Cai et al. (2001) aplicaron los AG en la solución de problemas no lineales de manejo del agua a gran escala. Ellos combinaron optimización lineal y AG con los cuales optimizaron una determinada cantidad de variables complejas, que fueron acopladas y ajustadas de tal forma que permitieran la descomposición del problema original en problemas de programación lineal más pequeños. Momtahan y Dariane (2007), utilizaron AG para encontrar las políticas de operación óptimas de un embalse en el Río Dez en el sudeste de Irán, ellos consideraron el suministro de agua como único objetivo de operación, y mediante AG determinaron las reglas de operación óptimas representándolas mediante funciones de aproximación, los resultados obtenidos fueron mejores respecto a los modelos de enfoques OEE y OEI.

Los modelos “Data driven” por su parte, como es el caso de las Redes Neuronales Artificiales (RNA) a pesar de no ser técnicas de optimización como tal, se han utilizado como alternativa al análisis de regresión lineal para determinar las reglas de operación de embalses (Labadie, 2004) en los enfoques OEI, por ejemplo. Entre otras cosas, estos modelos se han utilizado satisfactoriamente para predecir caudales de escorrentía como herramienta en la gestión de inundaciones, para la predicción de lluvias (French et al. 1992), además de múltiples aplicaciones en hidrología, hidrogeología e hidráulica en la modelación de ríos (Karunanithi et al. 1994). En la optimización de embalses, Raman y Chandramouli (1996) desarrollaron una política de operación óptima para el embalse Aliyar en Tamil Nadul, India, utilizando redes neuronales con resultados que mejoraron los modelos estocásticos tradicionales. Más adelante, este enfoque se extendió para el desarrollo de reglas de operación de sistemas de embalses múltiples (Chandramouli y Raman, 2001). A partir de estas nuevas técnicas, alternativamente a los enfoques OEE y OEI, algunos autores han propuesto otra metodología que consiste en la búsqueda directa de las políticas

de operación BDP (DPS por sus siglas en inglés). En este marco las reglas de operación óptimas se hayan directamente de la optimización aplicada a una familia de funciones que representan la operación del embalse. Los modelos BDP simulan las reglas de operación usando funciones de aproximación como RNA sobre las cuales se optimizan sus parámetros o variables de decisión con respecto a los objetivos del embalse. El término de este enfoque o metodología es atribuido a Rosenstein & Barto (2001), y en la literatura de los recursos hidráulicos también es conocido como parametrización-simulación-optimización como lo referencia Koutsoyiannis & Economou (2003) citados por Giuliani et al. (2016). A manera de resumen, en la figura 1 se muestran los principales marcos o enfoques encontrados en la literatura para la optimización de embalses y sus métodos más representativos.

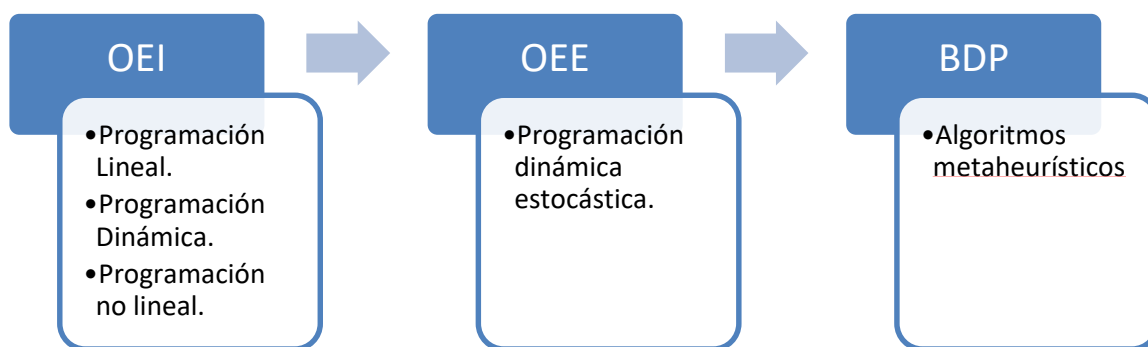


Figura 1. Metodologías para la optimización de embalses

Por su parte, los embalses multipropósito, requieren una consideración especial, teniendo la particularidad de que las diferentes metas de operación deben considerarse como objetivos simultáneos dentro del mismo problema. En estos problemas, la solución obtenida es una superficie de Pareto óptima de la cual se infieren las reglas de operación con base en los acuerdos entre los diferentes propósitos. Dentro de la optimización multiobjetivo, el método de ponderación es uno de los más utilizados, el cual convierte todos los objetivos en valores escalares mediante la asignación de ponderaciones subjetivas (Labadie, 2004). Variando las ponderaciones para cada uno de los objetivos se obtiene un conjunto de soluciones con el cual se evalúan los diferentes acuerdos para el problema. Las soluciones óptimas se pueden obtener a partir de los modelos tratados anteriormente (OEE y OEI).

Modelos de optimización multiobjetivo más recientes han tomado mayor protagonismo en los problemas de optimización de embalses, tal es el caso del algoritmo NSGAI (Deb, Pratap, Agarwal, & Meyarivan, 2002) y el MOEA/D (Zhang & Li, Dec. 2007). Castelletti, et al. (2011), por ejemplo, emplearon NSGAI bajo un enfoque BDP para la optimización del embalse Hoa Binh, del Río Da en Vietnam, el cual, fue evaluado para los propósitos de la generación de energía eléctrica, el suministro de agua y para el control de inundaciones. En este trabajo, la operación del embalse fue representada mediante funciones de RNA sobre las cuales fue aplicado el algoritmo de optimización, los resultados obtenidos permitieron demostrar que estas funciones de aproximación se ajustan adecuadamente a este tipo de problemas. Giuliani, et. al. (2016), realizaron el mismo análisis para este embalse, para los propósitos de la generación de energía eléctrica y para el control de inundaciones, en este estudio se incorporaron las Redes de Base Radial para la simulación de las reglas de operación, y se encontró que estas funciones se desempeñaron mejor que las RNA para el caso en estudio.

Otros trabajos recientes, han incorporado el enfoque BDP combinando diferentes algoritmos de optimización metaheurísticos para la optimización de embalses. Ritter (2016), por ejemplo, realizó la búsqueda directa de las reglas de operación óptimas en un sistema tipo cascada en la cuenca del Río Nechí en Colombia. Las funciones objetivo definidas fueron la maximización de la energía promedio generada por todo el sistema, la maximización de la energía firme, la minimización en el riesgo de inundación y la minimización de la alteración de los caudales aguas abajo del sistema. El modelo construido se ensambló a un algoritmo computacional llamado GODLIKE desarrollado en entorno MATLAB, el cuál mediante un procedimiento iterativo y utilizando 3 métodos de optimización (Algoritmos Genéticos, Evolución Diferencial y Swarm Particle) generó un frente de Pareto de cuatro dimensiones para los cuatro propósitos, creando múltiples reglas de operación para todo el sistema, las cuales fueron evaluadas y comparadas con las políticas de operación observadas del sistema (periodo 2012 – 2015). Se obtuvieron 45 reglas de operación optimizadas que mejoraron el desempeño de las reglas de operación observadas, obteniéndose mejoras considerables en cada una de los cuatro propósitos de operación. En conclusión, se observó que el uso de políticas directas (BDP) redujo la complejidad de los métodos de operación de sistemas de embalses multipropósito basados en funciones matemáticas parametrizadas.

Respecto al caso de estudio de la presente investigación, correspondiente a la cuenca del Río Yuna en República Dominicana, se han realizado estudios principalmente enfocados a modelos hidrológicos para la predicción de caudales. Robinson, (2009), por ejemplo, desarrolló un modelo hidrológico distribuido en donde se establecen los riesgos de inundación en la cuenca mediante mapas de inundación, el cual tiene en cuenta estructuras de control como diques y embalses al igual que enfoques no estructurales tales como alertas de inundación. Emanuelli (2017), por su parte, utilizó modelos de aprendizaje para la predicción de caudales a corto plazo y en tiempo real incorporando información espacio-temporal (información satelital), datos distribuidos, semidistribuidos y agrupados. Sin embargo, hasta el momento no se han desarrollado estudios que incluyan optimización de embalses y el impacto que esto tiene sobre la cuenca.

2.2 Algoritmos, Funciones de aproximación y entornos de desarrollo

En esta sección se describen las herramientas computacionales que se utilizaron en el presente estudio, partiendo de los algoritmos genéticos, los métodos multiobjetivo, hasta llegar al entorno de desarrollo empleado para su aplicación. Así mismo, se describen las familias de funciones utilizadas para los modelos de operación del embalse, funciones de regresión lineal, funciones de base radial y funciones de redes neuronales artificiales.

2.2.1 Algoritmos de optimización

2.2.1.1 Algoritmos genéticos

Los algoritmos genéticos (AG) son métodos de búsqueda aleatoria basados en los mecanismos de la evolución y selección natural (Loucks & van Beek, 2017), estos métodos son utilizados generalmente para resolver problemas de búsqueda y optimización. Actúan sobre una población de posibles soluciones generada

aleatoriamente para un determinado problema, en donde cada individuo de dicha población recibe una ponderación en razón a la solución que representa (medida conocida como adaptación). En la medida de que dicho individuo tenga mayor adaptación al problema, este tendrá más probabilidad de ser seleccionado para que se cruce con otro individuo, el cual es seleccionado de la misma manera, los individuos que menos se adapten al problema tendrán menos probabilidad de ser seleccionados para reproducirse. Mediante el cruce o combinación de los individuos más adaptados se producirán nuevos individuos que compartirán algunas de las características de sus padres. Este proceso se realiza hasta que el número de descendientes sea el mismo al de la población inicial.

Dentro de la población de descendientes obtenida se cambian aleatoriamente algunos de sus valores (mutación) y sobre este nuevo conjunto se evalúa la función objetivo del problema, si el valor de la función objetivo de uno de los descendientes es mejor que el de sus padres, el descendiente se insertará dentro de la próxima generación, de lo contrario, el mejor de los padres hará parte de la misma. Esta nueva generación se utiliza como base para la obtención de la siguiente, repitiendo el mismo proceso descrito anteriormente hasta que se alcance el criterio de detención del algoritmo, o hasta que no se observen mejores resultados en las generaciones obtenidas.

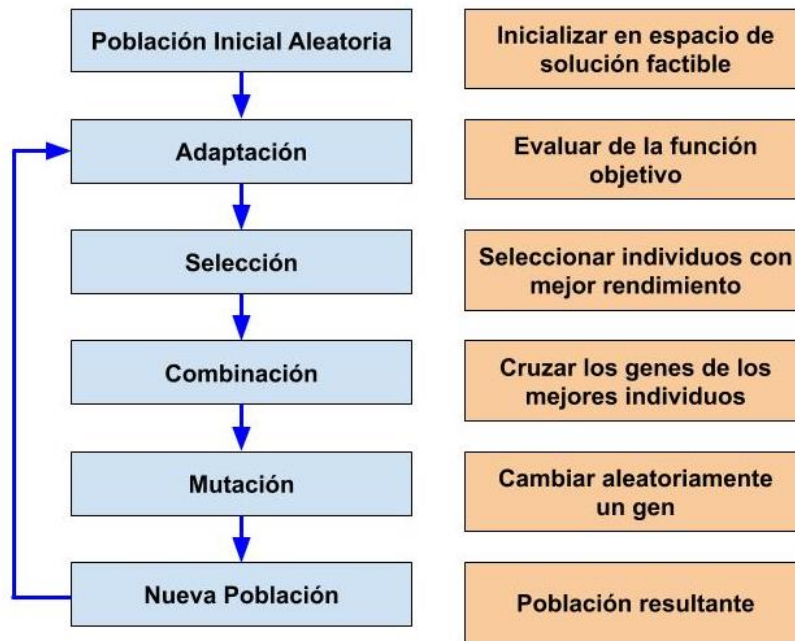


Figura 2. Flujograma para la aplicación de Algoritmos Genéticos

2.2.1.2 NSGA II

Los algoritmos evolucionarios como los AG fueron desarrollados inicialmente para solucionar problemas de un objetivo, sin embargo, para resolver problemas que involucran más de un objetivo, por ejemplo, el caso de un embalse en donde se tienen múltiples intereses de operación como el del presente estudio, el problema se convierte en encontrar un conjunto de soluciones no dominadas en lugar de una solución única, por lo tanto, es necesario incorporar el concepto de dominancia para saber que tan buena es una solución dada. Así entonces, si se tienen dos soluciones A y B, se determina que A domina a B si la solución A no es peor que B en todos los objetivos y además la solución A es estrictamente mejor que B en al menos uno de los objetivos .

Dentro de los algoritmos empleados para la solución de problemas multiobjetivo se encuentra el NSGA II (Non-dominated Sorting Genetic Algorithm II) desarrollado por Deb et.al. (2002). En este algoritmo se crea una población descendiente a partir de la generación anterior mediante un algoritmo de optimización como los algoritmos Genéticos, para cada individuo de la población de padres y descendientes se calcula la distancia de apiñamiento (“crowding distance”), la cual es la distancia promedio de cada individuo a los individuos que lo rodean dentro del espacio de la variable de decisión, entonces, se determina el número de individuos que lo dominan.

La siguiente generación se crea de la siguiente forma: Los individuos se insertan según su nivel de dominancia, siendo ingresados en primer lugar los individuos no dominados, después, aquellos que son dominados por un individuo, luego por dos, y así hasta que la nueva población tenga el mismo tamaño de la población inicial. A partir de esta nueva generación, se forman parejas de individuos las cuales se seleccionan de manera aleatoria y cada miembro se compara con el otro según su nivel de dominancia proceso conocido como “torneo de selección” (Ritter, 2016), si este es igual, el individuo ganador se determinará a partir del que tenga la distancia de apiñamiento más grande. Gracias a esto, el proceso asegura cierta dispersión y por lo tanto decrece la probabilidad de que converja hacia un mínimo local. Los individuos vencedores forman un nuevo subconjunto con un tamaño equivalente a la mitad de la población inicial. Este subconjunto se convierte en la población padre para crear una nueva generación descendiente del tamaño de la población inicial mediante un algoritmo de optimización (p. ej. AG), entonces se repite el proceso de verificar el nivel de dominancia para cada individuo de esta población descendiente y la generación padre, y los pasos subsecuentes descritos anteriormente. Este proceso se realiza hasta que todos los individuos sean no dominados. Los anteriores pasos se resumen en la Figura 3.

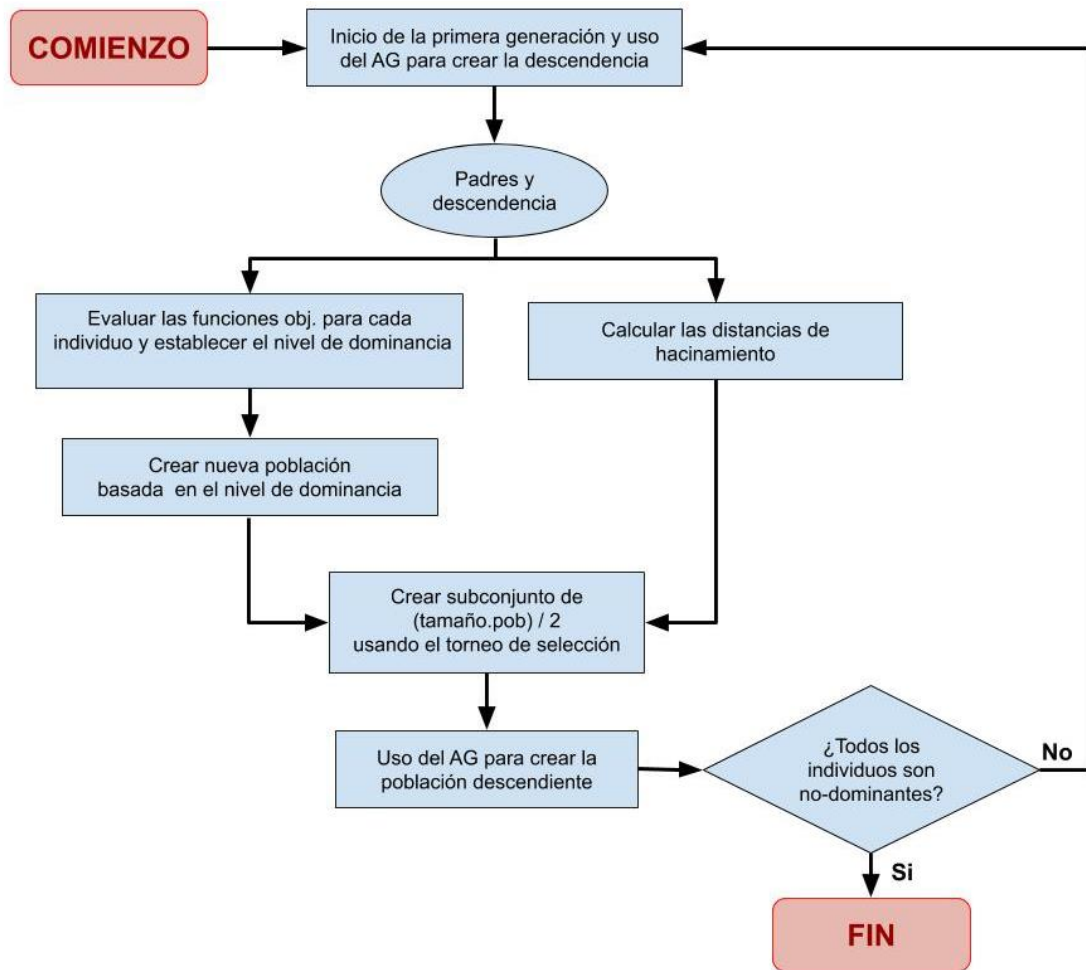


Figura 3. Flujograma del algoritmo NSGAII.

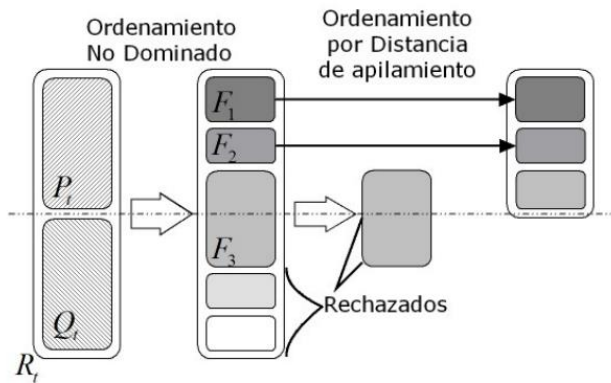


Figura 4. Diagrama esquemático del mecanismo de promoción de individuos del NSGA-II

2.2.1.3 MOEA/D

El MOEA/D (Multi-objective evolutionary algorithm based on decomposition) al igual que el NSGA II es un algoritmo de optimización multiobjetivo de propósito general creado por Zhang & Li (2007), el cual descompone el problema en subproblemas de un objetivo (o problemas de optimización simples) y cada uno de estos es optimizado simultáneamente utilizando información de sus subproblemas vecinos.

Los subproblemas creados son parametrizados mediante un vector de pesos, el cual sirve para orientar la búsqueda hacia una cierta zona del espacio de Pareto. La población correspondiente a cada generación se conforma de la mejor solución que se encuentra para ese momento en cada subproblema.

Una de las ventajas de este algoritmo respecto a otras técnicas de optimización multiobjetivo es que tiene una menor complejidad computacional en cada generación, dado que no requiere ningún proceso de clasificación de Pareto (Reyes-Hernández, Ponsich, & Hoyos-Reyes, 2018), usando una población pequeña puede generar soluciones finales uniformemente distribuidas, aunque para problemas de 3 o más objetivos el ajuste de los vectores de pesos es más difícil.

Los pasos del MOEA/D se muestran en la Figura 5. Una vez se crea y evalúa la población inicial se determinan las relaciones que existen entre los diferentes individuos de la misma zona (vecindario) con base a la cercanía entre los vectores de pesos que parametrizan cada subproblema, permitiendo calcular el punto ideal (z) que se emplea más adelante en la función de escalarización e iniciar la población externa (EP) la cual es un espacio en donde se administran las soluciones no dominadas. Después se generan nuevas soluciones de forma iterativa mediante operadores genéticos, se calcula su aptitud y se integran a la población externa (EP). Este ciclo generacional se repite hasta que se alcance el criterio de detención del algoritmo. Para efectuar la descomposición o escalarización g^{bip} , se utiliza la aproximación de intersección de frontera (Zhang Li, 2007), la cual consiste en encontrar puntos de intersección entre el límite óptimo del espacio de Pareto (p.ej. el límite inferior izquierdo para un problema de minimización) y un conjunto de líneas

que emanan del punto ideal (denotado como z). si estas líneas están distribuidas de manera adecuada, se puede esperar que los puntos de intersección resultantes proporcionen una buena aproximación, uniforme, de la totalidad del espacio de Pareto.

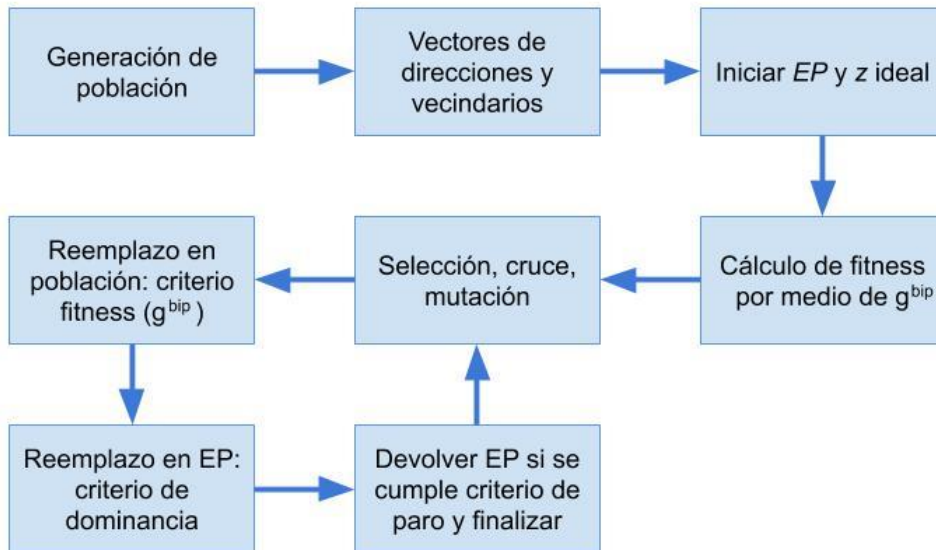


Figura 5. Flujograma del algoritmo MOEA/D

2.2.2 JMETALPY

JMETALPY es un entorno de optimización multiobjetivo desarrollado en Python, el cual aplica diferentes algoritmos metaheurísticos y otros métodos computacionales para la solución de problemas de optimización (tanto multiobjetivo como de un objetivo). El ambiente de JMETALPY consta de múltiples módulos que permiten aplicar diferentes técnicas de optimización, entre ellas los tres algoritmos mencionados (algoritmos genéticos, NSGAII y MOEA/D), al igual que un conjunto de aplicaciones para la visualización de resultados, frentes de Pareto y análisis de procesos en tiempo real junto con un diverso conjunto de propiedades relacionadas con la generación

automática de datos estadísticos. JMETALPY cuenta con diversos ejemplos para la solución de problemas clásicos de benchmark, lo cual permite entender cómo debe realizarse la incorporación de los problemas dentro de su entorno de trabajo y la aplicación de los algoritmos de optimización.

En el presente estudio se empleó el entorno JMETALPY para aplicar los algoritmos de optimización descritos anteriormente en la solución de los problemas planteados para el caso de estudio. El flujograma que se utiliza para la solución de problemas en el JMETALPY se muestra en la Figura 6.

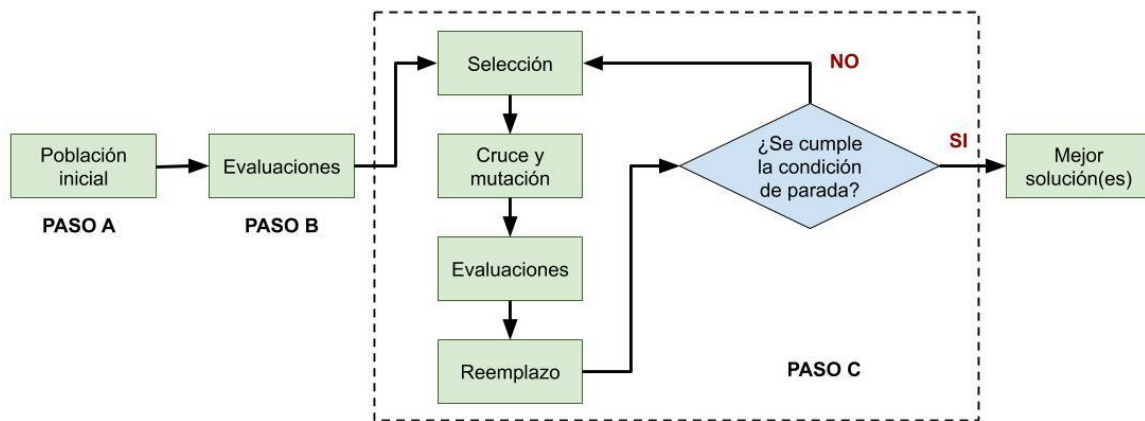


Figura 6. Flujograma del entorno JMETALPY

2.2.3 Funciones de aproximación

2.2.3.1 Redes neuronales artificiales

Muchos estudios han implementado las Redes Neuronales artificiales (RNA) como modelos de aproximación para la operación de embalses (Ehsani, Fekete, Vörösmarty, & Tessler, 2016), (Giuliani, Castelletti, Pianosi, Mason, & Reed, 2016), (Zhang, y otros, 2018) (Momtahn & Dariane, 2007). Las RNA son técnicas de modelación computacional basadas en el funcionamiento del sistema nervioso

humano, son ampliamente utilizadas para modelar sistemas no lineales gracias a su capacidad de ajustarse a estructuras, tendencias o patrones complejos. El Perceptron multicapa (PMC) es uno de los modelos de RNA más empleados, el cual pertenece al grupo de redes con conexiones “fedforward” (Hilera & Martínez, 2000) que se caracterizan por arquitecturas en niveles y conexiones realizadas hacia adelante. Las unidades de procesamiento de una RNA se conocen como neuronas las cuales están organizadas en capas. Una capa es un conjunto de neuronas cuya información siempre proviene de la misma fuente y cuya salida siempre se dirige al mismo destino.

El PMC está compuesto de varias capas de neuronas entre su entrada y salida, en la figura 7 se muestra un esquema general de un PMC. Las neuronas se unen entre las capas mediante conexiones las cuales tienen diferentes pesos o valores. La red neuronal tiene una capa de entrada con las neuronas en donde se introducen los datos, las capas ocultas en donde estos son procesados, y la capa de salida en donde se generan los resultados. La arquitectura mostrada en la Figura 7 corresponde a un PMC con una capa oculta en donde cada neurona recibe información de las neuronas de la capa de entrada y emiten un dato de salida; la salida de cada una de las neuronas corresponde a la sumatoria de cada uno de los productos entre cada valor de entrada (I_t) y cada uno de los valores de conexión (c_i), más el bias, teniendo en cuenta que además, el resultado anterior debe ser procesado mediante una función de activación que genera el dato de salida, estas funciones pueden ser la función sigmoide, función de tangente hiperbólica, función ReLU o función Softmax entre otras. La siguiente ecuación es la representación típica de las RNA, siendo u_k la salida de la Red.

$$u_k = a + \sum_{i=1}^N b_i \psi_i(I_t \cdot c_i + d_i)$$

En donde, N es el número de neuronas, $\psi(\cdot)$ es la función de activación de las neuronas (como la función sigmoide), I_t es el vector de entradas de la red; a, b_i, c_i, d_i son los parámetros de la RNA. El número de variables de decisión corresponde a $n_\theta = N(M + 2) + 1$, siendo M el número de variables de entrada al modelo.

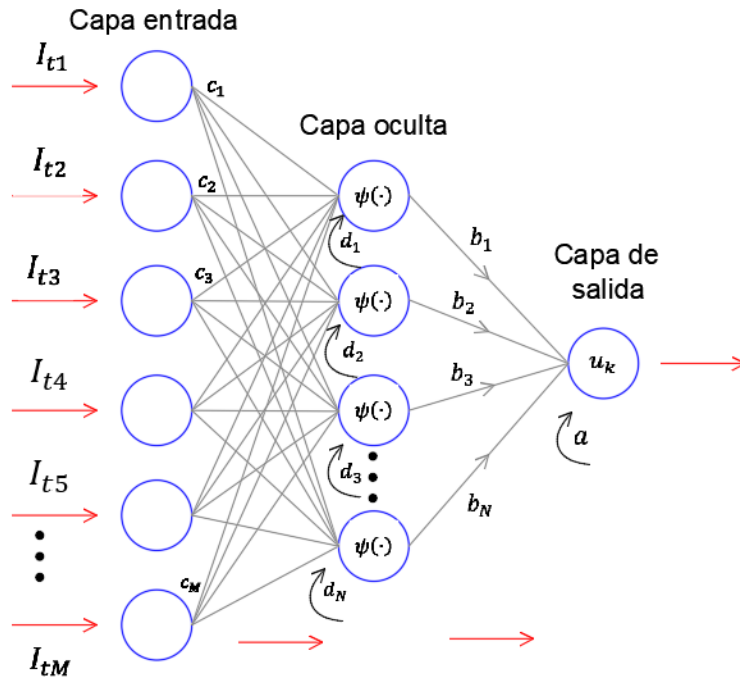


Figura 7. Esquema general de la arquitectura de una Red Neuronal Artificial

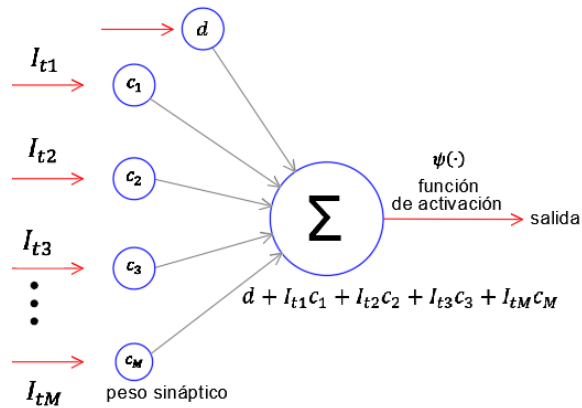


Figura 8. Operación interna en las neuronas de la Red Neuronal Artificial

El entrenamiento o aprendizaje de una RNA se realiza modificando los pesos de las conexiones entre las neuronas según el error obtenido en la salida y en función de cuanto haya contribuido cada neurona a dicho resultado. Uno de los métodos más utilizados es el Backpropagation (Rumelhart, Hinton, & Williams, 1986).

2.2.3.2 SCIKIT LEARN

Scikit Learn es un módulo de Python que integra un amplio rango de algoritmos de inteligencia artificial. Incluyendo algoritmos de clasificación, regresión y análisis de grupos entre los que se destacan los modelos lineales, máquinas de vectores de soporte, Procesos Gaussianos, Nearest Neighbors, Naive Bayes, árboles de decisión, Random Forest y modelos de Redes Neuronales Artificiales entre otros. Este módulo está diseñado para interactuar con bibliotecas numéricas y científicas como Numpy y SciPy Learn (Pedregosa et al. 2011). Numpy permite por ejemplo el uso de arreglos (matrices o vectores) para introducir y presentar los datos aplicados a Scikit Learn, permitiendo que la información se integre de forma correcta con las otras librerías de Python empleadas, además de proveer operaciones matemáticas básicas. Scipy por su parte provee algoritmos de algebra lineal, representación de matrices, funciones especiales y funciones estadísticas básicas.

En el presente estudio este módulo se utilizó para la implementación de redes neuronales artificiales con lo cual se busca determinar las reglas de operación actuales del embalse de Hatillo.

2.2.3.3 Redes de base radial

Las redes de Base Radial (RBR) son un tipo de Red Neuronal alimentada hacia adelante (feedforward) conformada únicamente por tres capas, una de entrada, una capa oculta y una de salida. La información al igual que en un PMC es transmitida desde la capa de entrada hacia la capa oculta, sin embargo, las funciones de activación en una RBR son funciones Gaussianas que a diferencia de las RNA realizan una transformación local y no lineal sobre dicha información (Cevallos Ampuero, 2008), las unidades de procesamiento generalmente se conocen como Bases (en lugar de neuronas, como en las RNA).

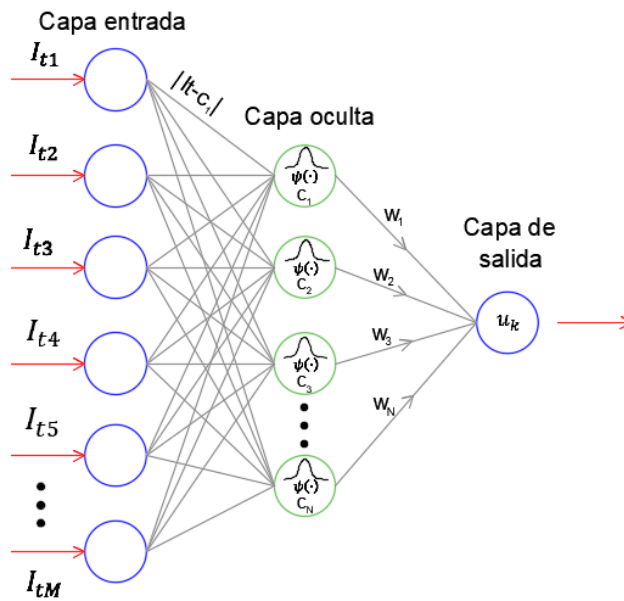


Figura 9. Esquema general de la arquitectura de una Red de Base Radial

La siguiente ecuación es la representación típica de las RBR, siendo u_t la salida de la Red.

$$\varphi_i(I_t) = \exp \left[- \sum_{j=1}^M \frac{[(I_t)_j - c_{j,i}]^2}{b_{j,i}^2} \right]$$

$$u_t = \sum_{i=1}^N w_i \varphi_i(I_t)$$

Donde, N es el número de Bases con función $\varphi(\cdot)$; w_i es el peso de la i th Base; M es el número de entradas I_t ; c_i , b_i son los vectores del centro y radio de M -dimensiones de la Base respectiva. El número de variables de decisión para un modelo de RBR es $N(2M + 1)$, siendo M el número de variables de entrada al modelo.

Al igual que las RNA, las RBR han sido implementadas como funciones de aproximación en la optimización de las reglas operacionales de embalses (Giuliani, Castelletti, Pianosi, Mason, & Reed, 2016) y (Giuliani, Herman, Castelletti, & Reed, 2014). Estas redes se distinguen de otros modelos debido a su aproximación universal y por tener una velocidad de aprendizaje superior (p.ej. PMC) (Ahmadian, 2016).

2.2.3.4 Regresiones lineales

Las regresiones lineales son funciones matemáticas utilizadas para encontrar relaciones entre variables con tendencias lineales, y a diferencia de las funciones anteriores, no tienen la capacidad de replicar de forma precisa patrones complejos (No lineales). Así entonces, sea Y_t una variable dependiente y X_p las variables independientes, el modelo se puede expresar de la siguiente manera:

$$Y_t = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p$$

Donde Y_t es la variable dependiente. X_1, X_2, \dots, X_p son las variables independientes. $\beta_0, \beta_1, \dots, \beta_p$ son los parámetros que miden la influencia que las variables independientes tienen respecto a la dependiente. p corresponde al número de parámetros independientes.

En el presente estudio se utiliza la función de aproximación lineal con el fin de encontrar las reglas de operación óptimas del embalse de Hatillo y comparar los resultados respecto a los otros modelos empleados que fueron descritos previamente.

3. Metodología de la investigación

En el presente capítulo se muestra la metodología empleada en este estudio. En la figura 10 se presentan los pasos seguidos, es importante mencionar que en este capítulo únicamente se presenta el contenido de la metodología, los pasos detallados y su aplicación se explican más adelante.

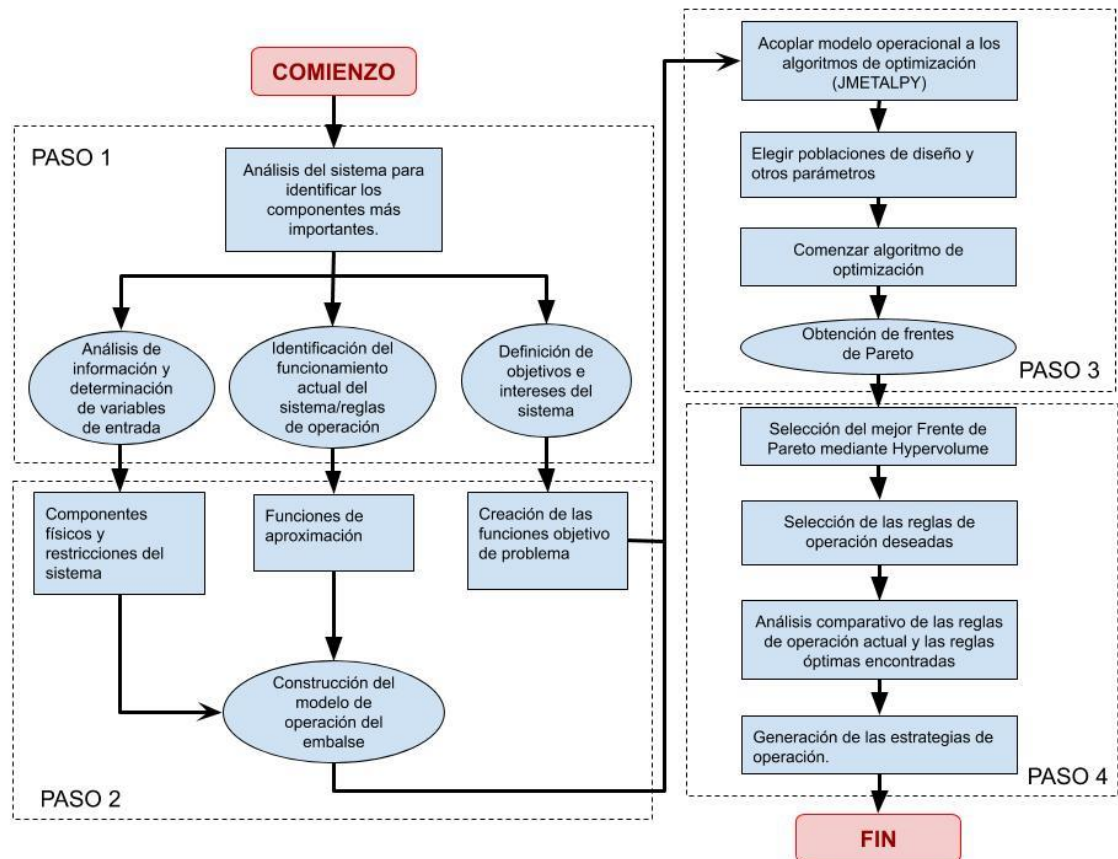


Figura 10. Flujograma de la metodología de investigación

3.1 Análisis del sistema

En este primer paso, se estudiaron los componentes del sistema, es decir, la información

que tiene relación con la operación del embalse, tal como caudales de entrada, niveles, y caudales de salida, lo cual corresponde a los datos disponibles de la operación del embalse. Así mismo, todos los propósitos involucrados, los cuales fueron el control de inundaciones, la generación de energía eléctrica y el suministro de agua para riego. Además, en este primer paso, se identificaron las reglas de operación actuales del embalse mediante el uso de herramientas de aprendizaje de redes neuronales artificiales. Cuando se hace referencia a reglas de operación actuales se refiere a las reglas de operación utilizadas para el periodo de estudio (2009-2019). Lo anterior sirvió de base para la elaboración de los modelos de operación propuestos en el siguiente paso.

3.1.1 Análisis de información

Los datos referentes a las variables de estado del embalse (Niveles diarios), caudales de entrada y descargas previas fueron analizados para evaluar su incidencia en la toma de decisiones para la operación actual del embalse. Por lo tanto, se aplicaron análisis de correlación entre los anteriores datos y los caudales de descarga. Lo anterior permite intuir las variables de entrada con mayor incidencia para la toma de decisiones en la operación actual del embalse, y por lo tanto, las más adecuadas para la aplicación de modelos de aprendizaje que permitan definir las reglas de operación actual.

3.1.2 Identificación de las reglas de operación actuales del sistema

Para definir las reglas de operación del embalse se emplearon técnicas de aprendizaje utilizando redes neuronales artificiales. Este método busca estimar las descargas del embalse en función de las variables de entrada definidas en el paso anterior. Lo que se realiza es un proceso de aprendizaje a partir de las series de datos definidos para las entradas, los cuales son asociados a los datos de salida registrados con el fin de “memorizar” y replicar estas salidas. Estos métodos han sido ampliamente usados para estimar reglas de operación de embalses como en

los estudios realizados por Ehsani N et al. , 2016; Zhang et al. , 2018; Raman & Chandramouli, 1996.

3.1.3 Definición de objetivos del sistema

Como se mencionó en la introducción, el embalse es utilizado para la generación hidroeléctrica, para el suministro de agua para riego y para el control de inundaciones. Estos propósitos fueron evaluados mediante funciones para evaluar su cumplimiento. Para tal fin, se emplearán funciones de poder como las utilizadas por Castelletti, et al. 2011.

3.1.3.1 Suministro de agua para riego

$$J_{min}^{hyd} = \sum_{t=0}^T (g_t^{sum})$$

$$g_t^{sum} = \begin{cases} 0 & \text{si } q_t^{ST} > w_t \\ (w_t - q_t^{ST})^2 & \text{de otra manera} \end{cases}$$

En donde J_{min}^{hyd} es la función objetivo para suministro de agua para riego la cual se buscó minimizar, g_t^{sum} es la función para el déficit en el suministro de agua en cada paso de tiempo t , w_t es la demanda diaria de agua para riego, q_t^{ST} es la descarga del embalse, T es el total de los pasos de tiempo evaluados. t es el periodo de tiempo de análisis actual.

3.1.3.2 Control de inundaciones

$$J_{min}^{flo} = \sum_{t=0}^T (g_t^{flo})$$

$$g_t^{flo} = \begin{cases} 0 & \text{si } h_t^{HN} \leq \bar{q} \\ (q_t^{ST} - \bar{q})^2 & \text{de otra manera} \end{cases}$$

En donde J_{min}^{flo} es la función objetivo para el control de inundaciones la cual se buscó minimizar, g_t^{flo} es la función para inundación en cada paso de tiempo t . q_t^{ST} es la descarga de agua del embalse, \bar{q} es el caudal de descarga de alarma de inundación,

$$P_{max}^{ener} = \sum_{t=0}^T q_t^{turb}$$

$$q_t^{turb} = \begin{cases} 0 & \text{si } r_t \leq q^{min} \\ \min(r_t, q^{max}) & \text{de otra manera} \end{cases}$$

En donde P_{max}^{ener} es la función objetivo de maximización de la potencia generada por turbinado, q_t^{turb} es el caudal turbinado en el tiempo t , r_t es la descarga del embalse, q^{max} es el caudal máximo que puede salir por turbinado, q^{min} es la descarga mínima que puede salir a través de las turbinas.

3.2 Construcción de los modelos de operación

El siguiente paso consiste en la construcción de los modelos de operación para el embalse empleando las ecuaciones de la conservación de la masa (balance hídrico) para cada paso de tiempo del periodo de análisis y considerando los componentes físicos y restricciones propias del sistema. Para la construcción de estos modelos de operación se tomaron los datos de caudales de ingreso para el periodo de análisis del embalse (2009-2019), los datos de evaporación media diaria de la zona, para los balances hídricos se tomó la batimetría del embalse que relaciona nivel, volumen y superficie. Para el cálculo de los caudales de salida se emplearon tres funciones de aproximación creando tres modelos de operación; el primero mediante Redes Neuronales Artificiales, el segundo mediante Redes Neuronales de Base Radial y un tercero mediante una función de regresión lineal. Cada uno de estos modelos considera las variables de entrada utilizadas en los modelos de aprendizaje

utilizados en el paso anterior, identificación de las reglas de operación actuales del sistema. Para las descargas se tiene en cuenta los caudales máximos y mínimos que pueden salir por las turbinas, válvulas de desfogue de fondo, o por el vertedero en función del nivel del embalse.

Los modelos de operación fueron construidos en Python para ser integrados directamente en el módulo de optimización JMETALPY, que hace parte del siguiente paso de la presente metodología.

3.3 Obtención de frentes de Pareto (optimización)

Para llevar a cabo la optimización fue necesario acoplar inicialmente los modelos operacionales a los algoritmos de optimización. Este proceso se realizó en la interfaz de JMETALPY, el cual fue el programa empleado para llevar a cabo las optimizaciones en el presente estudio. Los algoritmos de optimización utilizados son el NSGAI y MOEA/D, ambos hacen parte de los algoritmos incluidos dentro de los módulos del paquete JMETALPY. Una vez acoplados los modelos de operación a los algoritmos de optimización se eligen sus parámetros de funcionamiento: tamaño de población, mutación, cruzamiento, entre otros, y se realiza la corrida de los mismos. Los pasos que ejecuta el optimizador se pueden observar en la Figura 11.

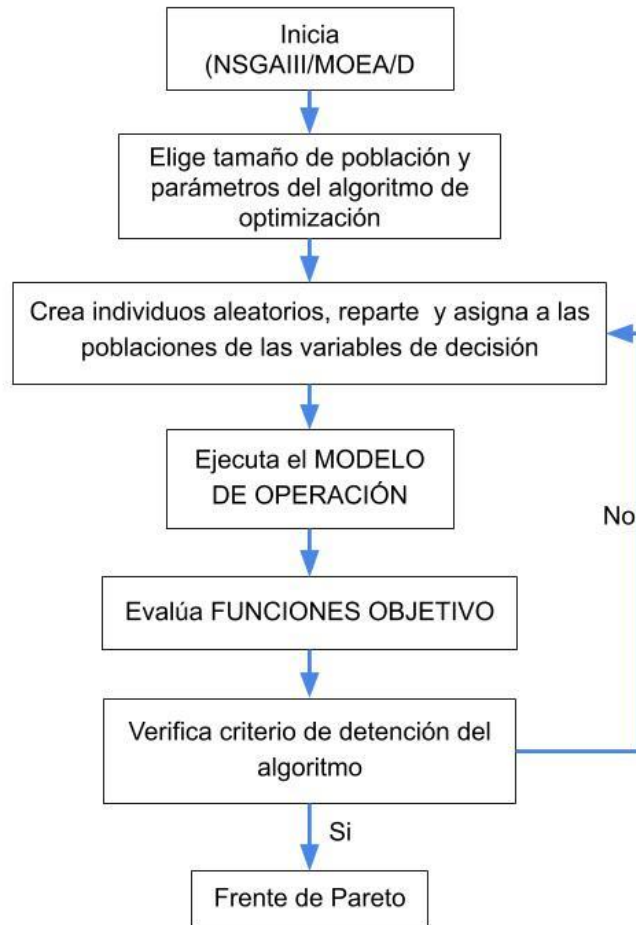


Figura 11. Flujograma optimizador JMOTALPY

3.4 Obtención de las reglas de operación óptimas

Mediante JMOTALPY se obtienen frentes de Pareto para cada uno de los modelos de operación y para los diferentes algoritmos utilizados. Por lo tanto, para elegir el mejor Frente de Pareto se pueden utilizar diferentes indicadores como el Hypervolume, el cual, es uno de los más utilizados para evaluar el desempeño de los algoritmos en problemas de optimización multiobjetivo (Guerreiro, Fonseca, & Paquete, 2005). Por lo tanto, en el presente estudio se utiliza el Hypervolume para determinar el mejor frente de Pareto.

Una vez obtenido el óptimo de Pareto final, se seleccionan las reglas de operación que se consideran más adecuadas respecto a los intereses u objetivos del presente estudio y se toman para evaluar y comparar respecto a las reglas de operación actual.

Para la verificación y validación final de las reglas de operación propuestas se generan series sintéticas de caudales de entrada; mediante este ejercicio se busca simular el comportamiento de las reglas de operación propuestas para datos que incorporan cierto grado de aleatoriedad, es decir para eventos no replicados de la serie de analizada (2009-2019). Estas reglas de operación son simuladas para la nueva serie de tiempo y son comparadas con las reglas de operación obtenidas para las condiciones actuales de operación del embalse, las obtenidas en el paso 1 de la presente metodología.

4. Caso de estudio

El caso de estudio que aborda esta investigación es el del embalse de Hatillo, el cual es un sistema multipropósito localizado en la Cuenca del Río Yuna en República Dominicana. La optimización multiobjetivo permite encontrar un espacio de decisión óptimo en el que los operadores pueden elegir a partir de las metas, prioridades o acuerdos, estableciéndose unas reglas de operación. Este paradigma aplica para el embalse de Hatillo en la medida de que su operación está orientada a la generación hidroeléctrica, al suministro de agua para riego y al control de inundaciones. Sin embargo, a lo largo de la historia son varios los eventos en los que se han presentado inundaciones aguas abajo del embalse como la del 5 de noviembre de 2007 (Tormenta tropical NOEL), o la del 24 de agosto de 2012 (Tormenta Tropical Isaac), entre otros. Por lo tanto, surge la pregunta de si es posible disminuir la ocurrencia de inundaciones o al menos reducir sus magnitudes mediante un manejo óptimo del embalse sin que se afecten o afectando mínimamente los demás objetivos del embalse. En este contexto, este caso de estudio aplica la optimización multiobjetivo para encontrar una respuesta a la anterior pregunta. En el presente capítulo, primero se describe la zona de estudio, es decir la cuenca en general y el embalse. Y segundo, se aplica la metodología explicada en el capítulo anterior.

4.1 Área de estudio

4.1.1 Cuenca del Río Yuna

La Cuenca del Río Yuna drena un área de 5498 Km², el cual recorre aproximadamente 210 Kilómetros que se extienden desde los Montes de San José de Ochoa hasta su desembocadura en la Bahía de Samaná. Su tributario más importante es el Río Camú, el cual tiene un recorrido de aproximadamente 100 Kilómetros desde la cordillera central en la Loma de la Sal hasta su entrega al Río Yuna.


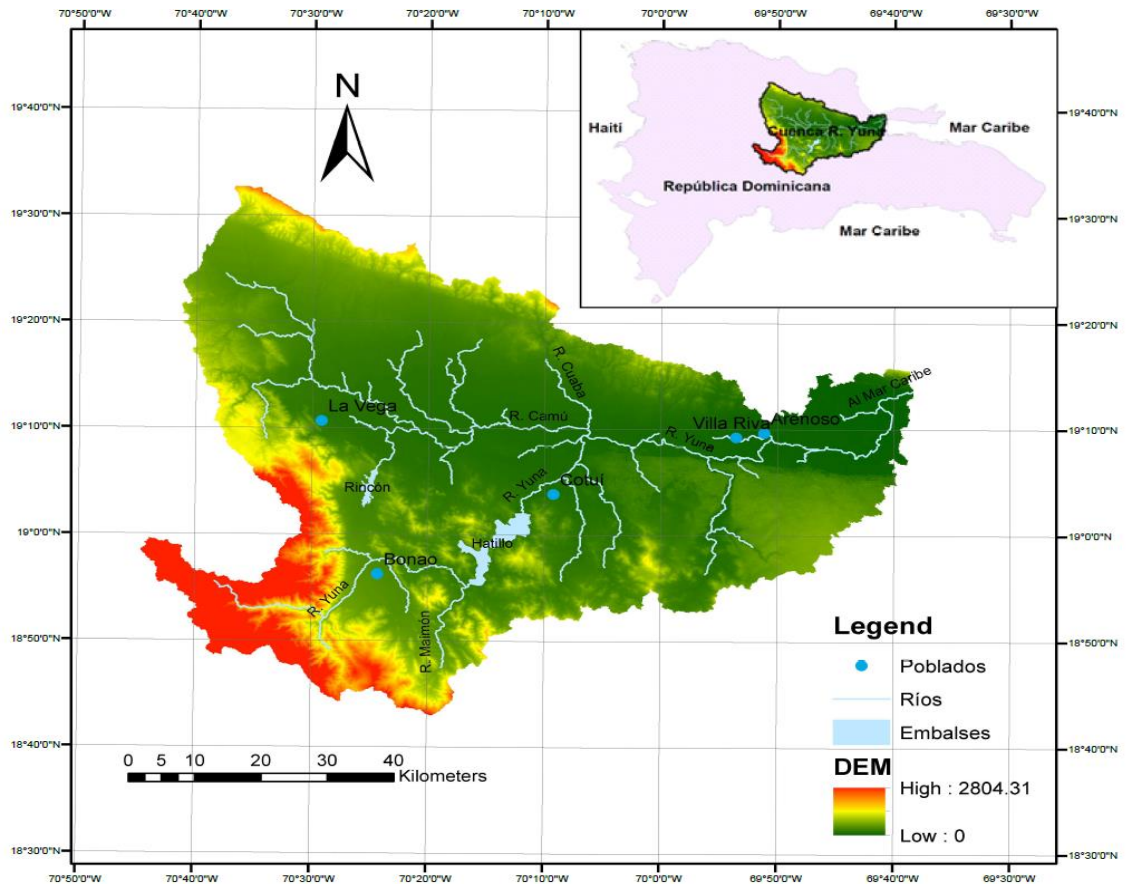



Figura 12. Localización general de la Cuenca del Río Yuna

La cuenca abarca una planicie que va desde su zona noreste, hasta su noreste. La zona Sur y suroeste por su parte corresponden a relieves de altitud media y alta dominados por terrenos escabrosos de montaña. En general las elevaciones van desde el nivel del mar hasta los 2804 m.s.n.m. En la figura 13, se muestra la localización general del área de estudio, ilustrando el relieve y el rango de elevaciones de toda la cuenca, sus principales ríos, embalses y las poblaciones más importantes.

El río Yuna es el segundo río más importante de la República Dominicana después del Río Yaque del Norte, siendo el Yuna más caudaloso con un flujo medio de 91 m³/s en su desembocadura. Sus principales afluentes son el Río Maimón hacia el sur, y los Ríos Camú y Cuabá hacia el Norte. Según el Ministerio de Medio Ambiente y Recursos Naturales (2020), el uso del suelo esta dominado por la agricultura, principalmente cultivos de arroz, cacao y pasto hacia la planicie de la cuenca, en esta zona se presentan también bosques latifoliados; en la zona media se presentan áreas de bosque latifoliados nublados y hacia la zona más alta bosques de coníferas densos.



(a)



(b)

Figura 13. Cuenca Río Yuna: (a) Localización y componentes Cuenca Río Yuna, (b) Modelo de elevación digital Cuenca Río Yuna.

En la actualidad, únicamente el 26 % del área total de la Cuenca está regulada por embalses, los más importantes son Hatillo y Rincón, siendo Hatillo el más representativo regulando el 23 % del área total de la cuenca (el 3% restante es regulado por Rincón). En la figura 14 se muestra el área de drenaje que corresponde a cada uno de los embalses. Nótese que la zona regulada abarca el suroeste de la cuenca, es decir la zona media y alta. La capacidad de almacenamiento de los embalses es de 441 Millones de metros cúbicos para Hatillo y 75.5 Millones de metros cúbicos para Rincón.

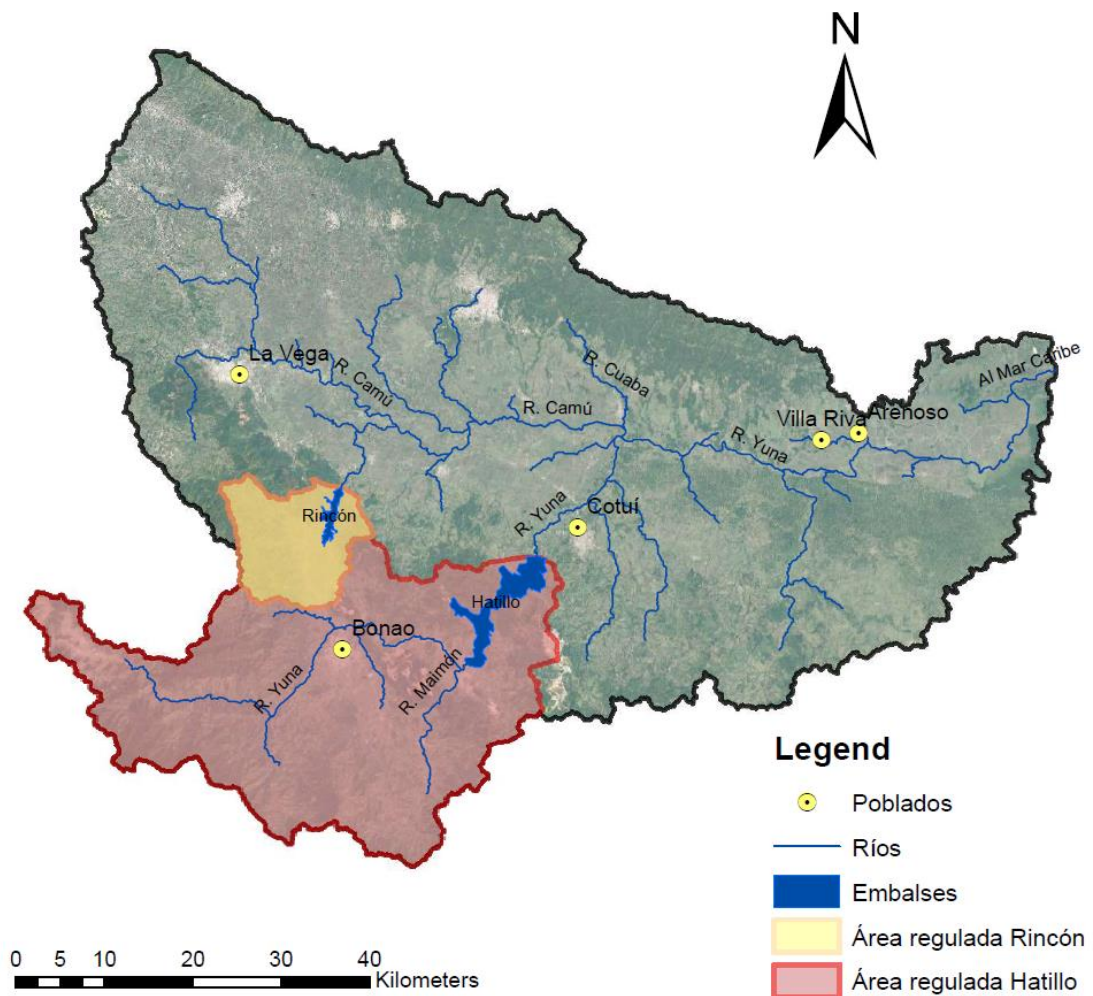


Figura 14. Área regulada por embalses en la Cuenca del Río Yuna

La precipitación media anual en la cuenca del Río Yuna oscila entre los 1080 y 3120 mm, la zona de mayor precipitación corresponde al suroeste de la cuenca, es decir la zona de montaña; De forma opuesta, hacia el noroeste es donde se presentan las menores precipitaciones (Cuenca del Río Camú). En la figura 15, se presenta un mapa de precipitaciones medias anuales elaborado a partir de los datos de las estaciones pluviométricas del área de estudio.

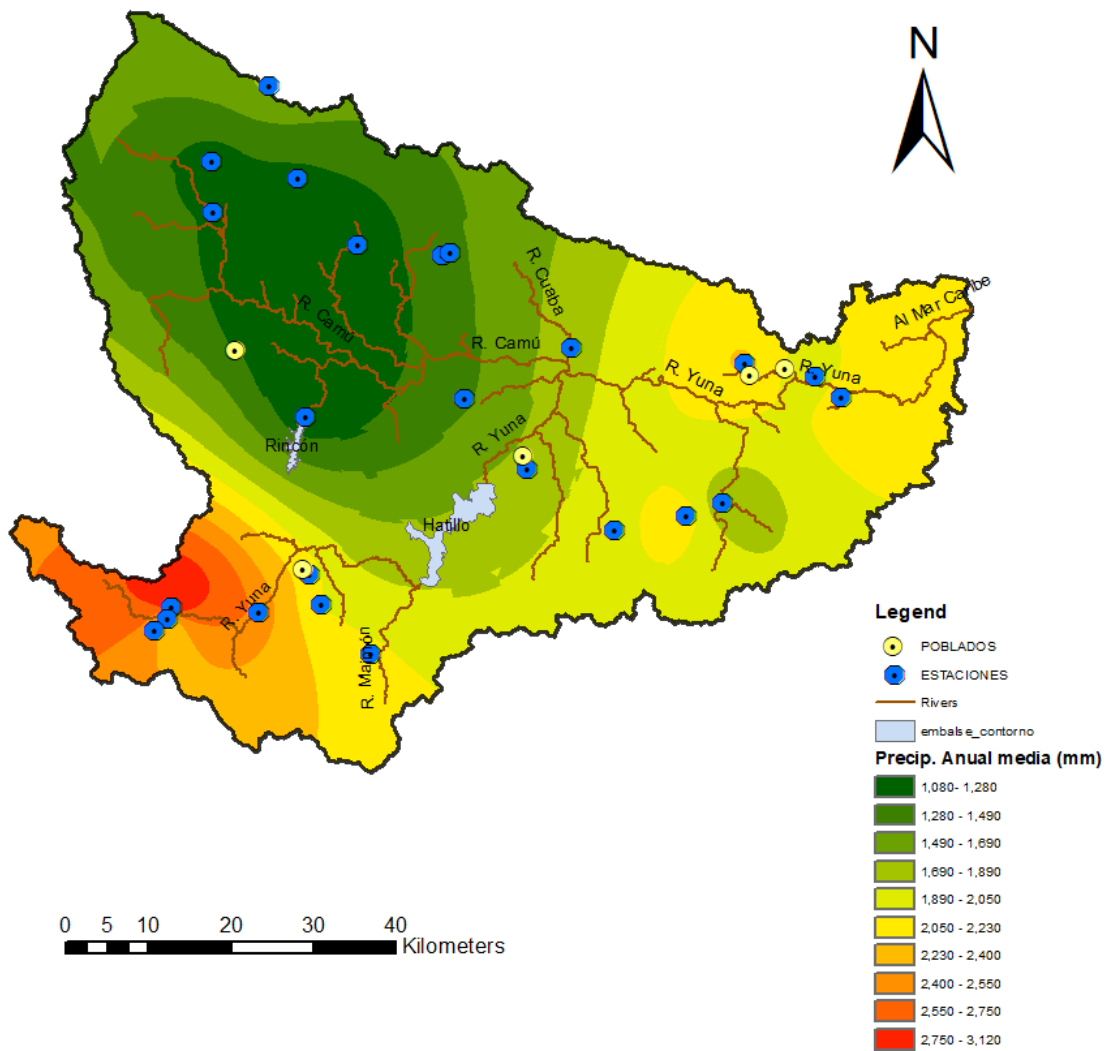


Figura 15. Mapa de precipitaciones medias mensuales en la Cuenca del Río Yuna

4.1.2 Embalse de Hatillo

El embalse de Hatillo es el cuerpo de agua superficial más grande de República Dominicana abarcando 27.4 Km² en promedio, tiene los propósitos de generar energía eléctrica, suministrar agua para riego y mitigar inundaciones en los poblados aguas abajo. En la figura 16 se muestra la localización general del embalse dentro de la cuenca, en donde se puede apreciar que se encuentra sobre su zona media, regulando un área de 1192 Km². El caudal medio del Río Yuna al ingreso del embalse es de 35.4 m³/s. Las características y componentes más importantes del sistema se muestran en la figura 17. En resumen, este sistema cuenta con una presa construida en tierra y enrocado, la cual tiene una altura de 50 m. El embalse tiene una capacidad de almacenamiento total de 441 millones de metros cúbicos, teniendo una longitud máxima de 15 Km. Los niveles de funcionamiento son: 70 m.s.n.m para el nivel mínimo de operación, 86.5 m.s.n.m para el nivel de operación máximo que corresponde a la cota de la cresta del vertedero y un nivel máximo extraordinario que corresponde a la cota 100.75 m.s.n.m.

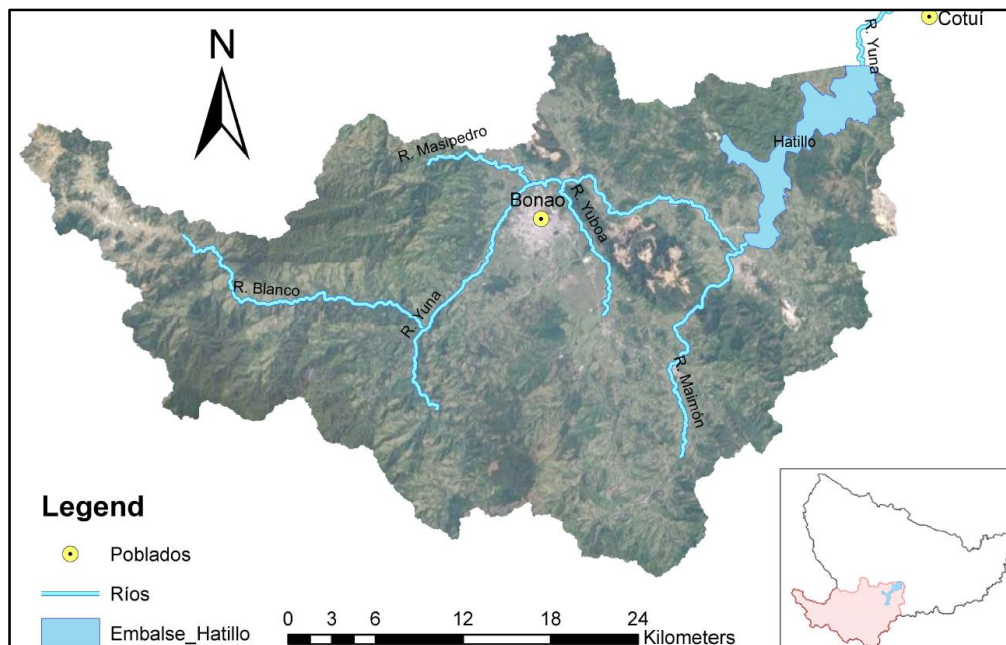


Figura 16. Área de regulación embalse de Hatillo

El sistema cuenta con un vertedero de superficie libre el cual tiene una capacidad máxima de $650 \text{ m}^3/\text{s}$; cuenta con un cuarto de máquinas en donde se encuentra una turbina Francis con una capacidad instalada de 8 Mw y una producción anual de energía de 40 Gwh. Además, cuenta con dos válvulas de chorro hueco para el desfogue de fondo del embalse las cuales tienen una capacidad máxima de desfogue de $82 \text{ m}^3/\text{s}$ cada una.

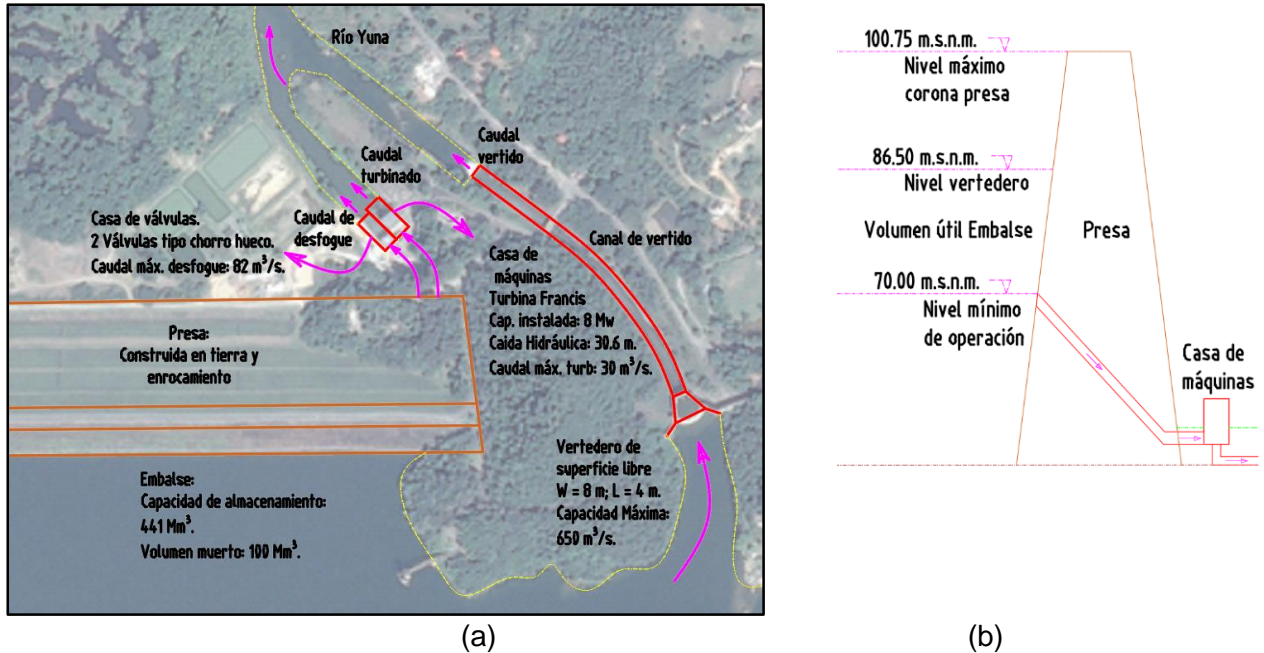


Figura 17. Componentes del embalse de Hatillo. Vista en planta de los componentes de la Presa. (b) Niveles de operación.

4.2 Descripción específica del problema

Uno de los principales problemas que se presenta en la cuenca tiene que ver con las inundaciones que ocurren en el bajo Yuna durante periodos de lluvias prolongadas que generan el aumento del caudal del río y en consecuencia los desbordes y afectaciones en las poblaciones bajas como Cotuí, Villa Riva y Arenoso. En general, la planicie del bajo Yuna es una zona susceptible de inundaciones caracterizadas por un relieve de pendientes bajas y extensas llanuras, allí se han reportado ya numerosos eventos como el que se

registró entre el 28 y 30 de octubre de 2007 producto del paso de la Tormenta tropical NOEL que afectó a todo el territorio Dominicano con pérdidas que superan los 439 millones de dólares (CEPAL. NACIONES UNIDAS, 2008). En la figura 18 se muestra la planicie de inundación presentada para ese evento en el bajo Yuna en donde se observa una afectación considerable sobre poblaciones ribereñas como Viña Riva y Arenoso, así como parte de poblados localizados aguas arriba como Cotuí. Como se puede apreciar en la imagen esta zona de inundación se encuentra localizada aguas abajo del embalse de Hatillo, por lo tanto es importante mencionar que, aunque los eventos de inundaciones en el bajo Yuna no están relacionados con la operación del embalse, se contempla la posibilidad de encontrar reglas de operación óptimas que permitan reducir la magnitud de estas inundaciones en los poblados aguas abajo. En el presente estudio únicamente se tiene en cuenta el embalse de Hatillo en la medida de que el embalse Rincón representa un área de regulación muy pequeña respecto al área total de la cuenca, por lo que se deduce que su operación no tendría mayor impacto sobre la reducción de las inundaciones en esta zona.

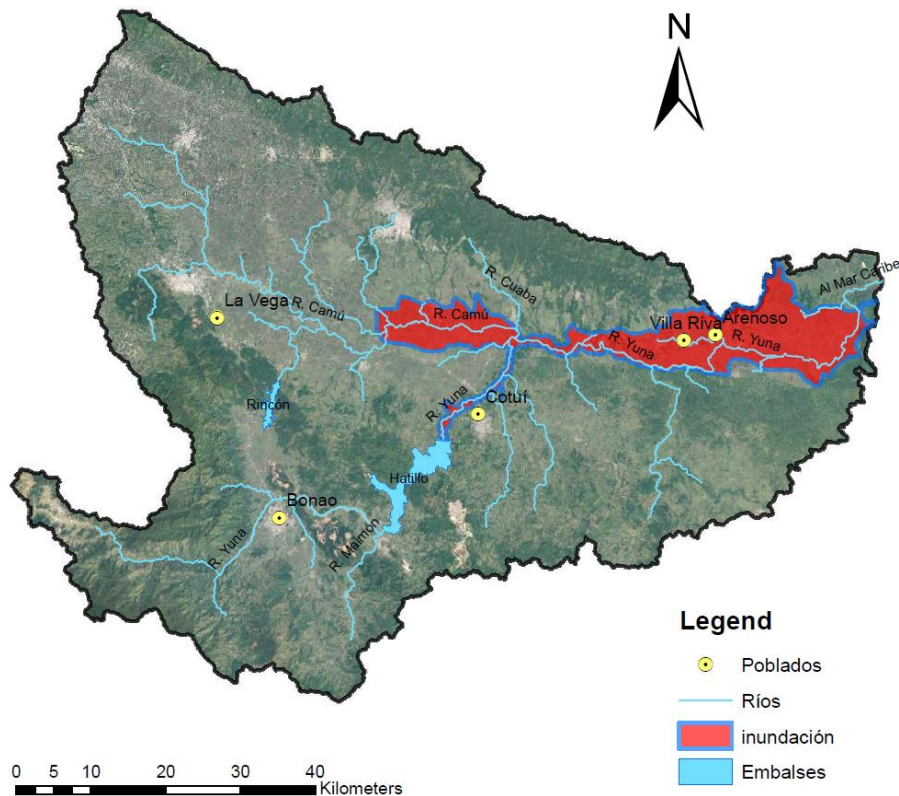


Figura 18. Planicie de inundación en el Bajo Yuna

Otros eventos de inundaciones más recientes se presentan en la siguiente tabla, siendo identificados desde el más reciente hasta el más antiguo.

Tabla 1. Eventos de inundaciones en el Bajo Yuna en los últimos 11 años.

Id	Evento	Fecha
1	Ola invernal	enero de 2018
2	Ola invernal	abril de 2017
3	Ola invernal	noviembre de 2016
4	Tormenta tropical Chantal	julio de 2013
5	Tormenta tropical Isaac	agosto de 2012
6	Ola invernal	abril de 2012
7	Ola invernal	julio de 2010
8	Ola invernal	junio de 2011
9	Ola invernal	mayo de 2009
10	Ola invernal	febrero de 2009

4.3 Recolección de Datos y Procesamiento

Los datos utilizados en el presente estudio están relacionados con la operación del embalse, es decir, series de tiempo de caudales de entrada, caudales de salida, niveles del embalse y Batimetría, para los cuales fueron tomados pasos de tiempo a escala diaria en un periodo de análisis que abarca desde el 2009 hasta el 2019, información que fue suministrada por la Empresa de Generación Hidroeléctrica Dominicana (EGEHID). En la figura 19 se muestran los valores de entrada y salida de caudal para el embalse que tuvieron lugar en el periodo de análisis (2009-2019), los números al interior del gráfico indican los picos de caudales del embalse (entrada y salida) para los mismos intervalos de tiempo en que se presentaron los eventos de inundación mencionados anteriormente. Cabe destacar que estos datos corresponden únicamente a los datos de entrada y de salida del embalse y no a los caudales que generaron las inundaciones.




Figura 19. Caudales de entrada y de salida del embalse de Hatillo para el periodo 2009-2019.




Figura 20. Batimetría embalse de Hatillo (Nivel vs Volumen)




Figura 21. Niveles del embalse de Hatillo para el periodo 2009 - 2019.

4.4 Aplicación de la metodología de la investigación

4.4.1 Análisis del sistema

4.4.1.1 Análisis de información

Para identificar las reglas de operación actual del embalse mediante modelos de aprendizaje, es importante definir las variables de entrada que mejor se ajustan o guardan relación con la información de salida, lo anterior es posible mediante la aplicación de técnicas de análisis de correlación. Esta herramienta ha sido utilizada

con éxito en otros estudios para la selección de variables de entrada en modelos con redes neuronales artificiales (Corzo Perez, 2009), (Emanueli Gandara, 2017).

4.4.1.2 Selección de entradas con base en un análisis de correlación

El coeficiente de correlación se usa de manera frecuente para determinar relaciones matemáticas lineales entre dos variables o entre series de tiempo. En la aplicación de modelos de aprendizaje o regresivos, las variables de entrada que más se utilizan en la operación de embalses son los caudales de entrada, los niveles del embales y las descargas previas, (p. ej. Ehsani N et al. , 2016). Por lo tanto, para estas variables y sus valores anteriores (Lagg) se busca determinar su correlación con los caudales de descarga del embalse x_i para cada paso de tiempo. La correlación entre dos variables x_i y y_i se puede expresar como:

$$\rho_{xy} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n \bar{x})^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n \bar{y})^2}}$$

Donde ρ_{xy} es el coeficiente de correlación, x_i es la descarga del embalse, y_i es la variable a correlacionar (Caudales de entrada, niveles o caudales de salida), \bar{x} y \bar{y} son las medias de las series de tiempo.

En el presente estudio se tienen las series de tiempo de caudales de entrada, los niveles del embalse y los mismos caudales de salida con tiempo de retardo, como variables de entrada para la modelación de las reglas de operación actuales; el periodo abarca desde el 2009 al 2019 en pasos de tiempo diarios.

Frecuentemente, en modelos de operación de embalses se evalúa la incidencia de los valores previos de las series de entrada (lag time). Es allí donde surge la duda, cual es el tiempo de rezago de la respectiva serie que tiene más correlación con la

variable de salida actual (descarga del embalse). Debido a que el coeficiente de correlación puede ser engañoso en la medida de que podrían existir ciertos eventos con una estructura de correlación diferente, se considera realizar un análisis de correlación para diferentes rangos en la variable de salida. En la figura 22 se muestran las correlaciones para cada una de las series de entrada consideradas, tomando todos los datos de las respectivas series de tiempo.

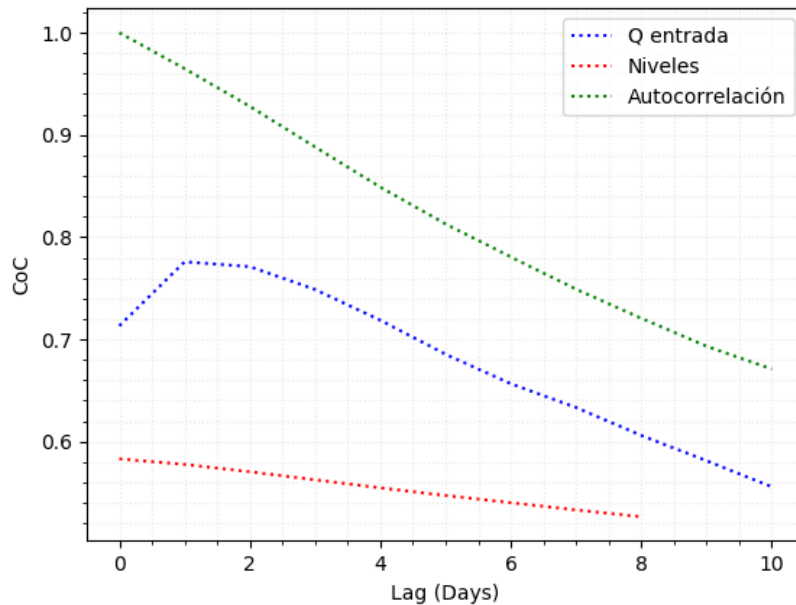


Figura 22. Análisis de correlación entre caudales de entrada vs caudales de salida; Niveles vs Caudales de salida; y Autocorrelación del caudal de salida

Correlación Caudal de salida y caudal de entrada

Tomando como base lo anterior, se realizó el ejercicio de evaluar el coeficiente de correlación entre el caudal de salida y el caudal de entrada con tiempos de retardo (Lag) de 10 días. Lo anterior considerando diferentes rangos para los caudales de salida con intervalos de $10 \text{ m}^3/\text{s}$, así entonces, para un valor límite de $0 \text{ m}^3/\text{s}$ significa que se evaluaron la totalidad de los datos de la serie de tiempo, para un valor límite de $10 \text{ m}^3/\text{s}$ significa que se evaluaron los caudales que estaban por encima de $10 \text{ m}^3/\text{s}$, para un valor límite de $20 \text{ m}^3/\text{s}$ los caudales que estaban por encima de $20 \text{ m}^3/\text{s}$ y así sucesivamente. Esto con el fin de analizar la correlación en diferentes

rangos de los caudales de salida. En la figura 23 se muestra la gráfica de correlación para diferentes rangos de caudales de salida del embalse.

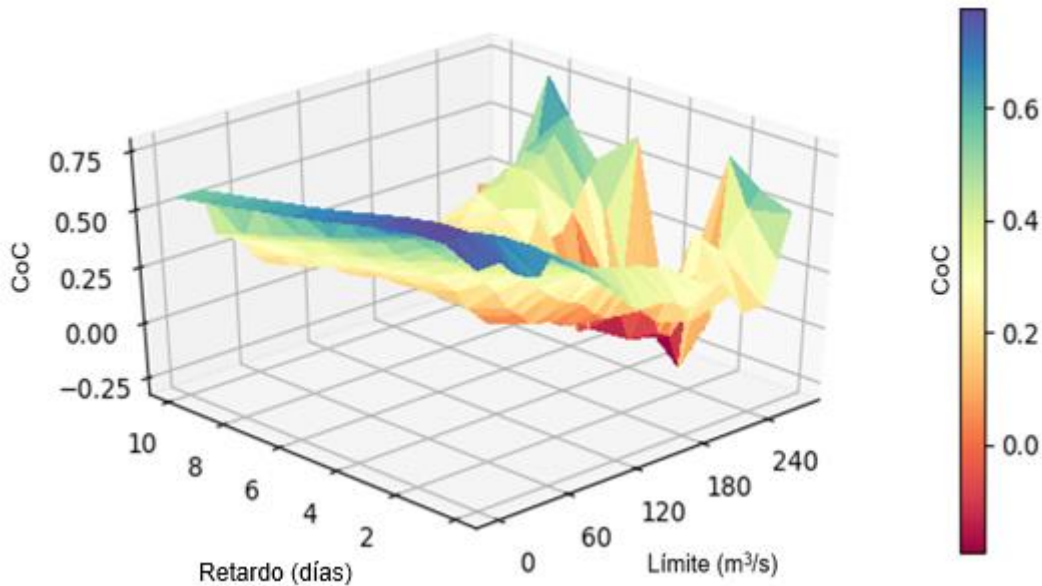


Figura 23. Superficie de correlación entre Caudal de salida y caudal de entrada para diferentes rangos de caudales de salida del embalse y diferentes retardos (Lags).

Como se puede observar los valores más altos de correlación se obtienen para retardos en los caudales de entrada de 1 y 2 días y tomando todos los valores de la serie de caudales de salida. Se observa que para eventos con caudales de descarga superiores a $120 \text{ m}^3/\text{s}$, la correlación disminuye considerablemente para retardos superiores a 2 días. Lo anterior, podría explicarse por el hecho de que caudales de esa magnitud corresponden a valores fluctuantes o pulsos de un hidrograma de entrada que no se ven reflejados en la descarga por el efecto de la atenuación del embalse. Sin embargo, se observa que para eventos con límites superiores a $240 \text{ m}^3/\text{s}$ existe una correlación alta para retardos comprendidos entre 6 y 8 días. Esto último, sin embargo, obedecería a una muestra muy pequeña del total de datos de las series por tratarse de eventos puntuales, por lo tanto, no son representativos.

Correlación caudal de salida y Niveles

Se realizó también el ejercicio de evaluar el coeficiente de correlación entre el caudal de salida y los niveles del embalse con retardos de 8 días, para diferentes rangos de los caudales de salida tomando intervalos de 10 m³/s. En la figura 24 se muestra la gráfica de correlación respectiva.




Figura 24. Superficie de correlación entre Caudal de salida y Niveles del embalse para diferentes rangos de caudales de salida del embalse y diferentes retardos.

Se observan coeficientes de correlación relativamente altos para todos los 8 días de retardo de los niveles del embalse y tomando la serie completa de caudales de salida, existiendo una correlación un poco más alta para los dos primeros días. Por otra parte, se observa que para caudales de descarga comprendidos entre 150 y 250 m³/s la correlación es muy baja, lo cual podría darse por fluctuaciones grandes causadas por eventos extremos. Sin embargo, para eventos de caudales de salida superiores a 270 m³/s la correlación es nuevamente alta siendo levemente superior para los días 4, 5, y 6. Esto último, sin embargo, obedecería a una muestra muy

pequeña del total de datos de las series por tratarse de eventos puntuales, por lo tanto, no son representativos.

Autocorrelación de los caudales de salida

Finalmente, se realizó el ejercicio de evaluar el coeficiente de autocorrelación del caudal de salida para 10 días de retardo en diferentes rangos de los caudales tomando intervalos de 10 m³/s. En la figura 25 se muestra la gráfica de Autocorrelación.




Figura 25. Autocorrelación de los caudales de salida del embalse para un lag de 10 días y para diferentes rangos de caudales

Nótese que los valores de autocorrelación aún para los 10 días de retardo siguen siendo relativamente altos, sin embargo, se observa que para caudales de salida por encima de los 60 m³/s, y para retardos superiores a 2 días la correlación disminuye considerablemente.

Selección de variables de entrada

Como se puede observar en la figura 22, la correlación entre los caudales de salida y los caudales de entrada es considerablemente alta para los 10 días de retardo, de lo cual, se puede intuir que se podrían tomar diferentes retardos para el modelo, sin embargo, la figura 23 muestra que para caudales superiores a 120 m³/s la correlación con retardos superiores a 2 días decrece notoriamente, por lo tanto, se toman los caudales de entrada para tiempos de retardo de 1 y 2 días como variables de entrada.

Por otra parte, aunque los valores de correlación no son muy altos entre los niveles y los caudales de salida, se puede observar una correlación relativamente alta para niveles con retardos de 2 días si se considera toda la serie de tiempo de caudales de salida. Por lo tanto, se toman los niveles del embalse para tiempos de retardo de 1 y 2 días como variables de entrada.

Finalmente, teniendo en cuenta los retardos de los caudales de salida se puede evidenciar que la autocorrelación es alta para los dos primeros días, y para todos los rangos de caudales de salida evaluados, razón por la cual se toman estas dos variables como datos de entrada.

4.4.2 Identificación de las reglas de operación actuales del embalse

Las reglas de operación de un embalse, como ya se mencionó antes, pueden representarse mediante funciones o parámetros para encontrar los caudales o volúmenes de descarga en cada paso de tiempo. Por lo tanto, la identificación de las reglas de operación no es otra cosa sino parametrizar la forma en que se opera el

embalse, que para el caso de estudio obedece a la manera en que se operó durante el periodo 2009 - 2019. Para lo anterior, se utilizaron modelos de aprendizaje con Redes Neuronales Artificiales (RNA) buscando replicar los caudales de salida del embalse a partir de los datos de entrada seleccionados. Las series de tiempo de los caudales de entrada, retardos de los caudales de salida y niveles del embalse fueron empleadas como datos de entrada para los modelos. En el presente estudio se utilizó el módulo Scikit Learn de Python, para aplicar el modelo de RNA.

4.4.2.1 Redes neuronales artificiales

El modelo utilizado corresponde al Perceptrón multicapa (PMC), antes de la construcción de la Red Neuronal artificial se realizó la estandarización de los valores de entrada con el fin de restringir los datos de salida dentro de un rango en donde la función de activación aplique (Emanueli Gandara, 2017). En el presente estudio se empleó el método de puntuación estándar, el cual, tiene en cuenta la varianza y el promedio de toda la serie de tiempo. La expresión que lo describe se muestra a continuación:

$$X_n = \frac{X - \mu}{\sigma}$$

Donde X es el valor de la variable sin normalizar, μ es el promedio de la serie de tiempo y σ es el valor de la varianza de la serie de tiempo.

La configuración de la arquitectura de la Red Neuronal generalmente se elige con base en pruebas de ensayo y error. Estudios similares han encontrado que una capa oculta es suficiente para llegar a una convergencia óptima en el entrenamiento de una red, por lo tanto, en el presente estudio se empleó una arquitectura conformada por una capa oculta, probando diferentes números de neuronas para esta capa. Para el entrenamiento de la red se utilizó el 80% de los datos de las series de tiempo, lo cual corresponde a los 3072 datos iniciales del periodo de análisis. Por su parte, para el test de la red se empleó el 20 % restante correspondiente a los 768 datos finales.

La función de activación empleada para las neuronas fue la sigmoide, y el solucionador (solver) para encontrar los pesos óptimos fue el lbfgs, el cual es un método de optimización que pertenece a la familia de los Métodos quasi-Newton de funciones. Para evaluar el desempeño de la red se emplearon el error cuadrático medio MSE y el error absoluto medio MAE. En la figura 26, se puede observar la arquitectura de la Red Neuronal con los mejores resultados obtenidos en el test, para determinar esta configuración fueron evaluados numerosas arquitecturas con diferentes cantidades de neuronas. En donde Q_{et-2} corresponde a los caudales de entrada al embalse para un tiempo de retraso de 2 días y Q_{et-1} para 1 día. N_{t-2} corresponde a los niveles del embalse para un tiempo de retraso de 2 días y N_{t-1} para 1 día. Q_{st-2} corresponde a los caudales de salida del embalse para un tiempo de retraso de 2 días, Q_{st-1} para 1 día y Q_{st} es el valor de la descarga para el periodo actual. Para esta configuración se obtuvieron 57 parámetros (49 pesos) y 8 biases.

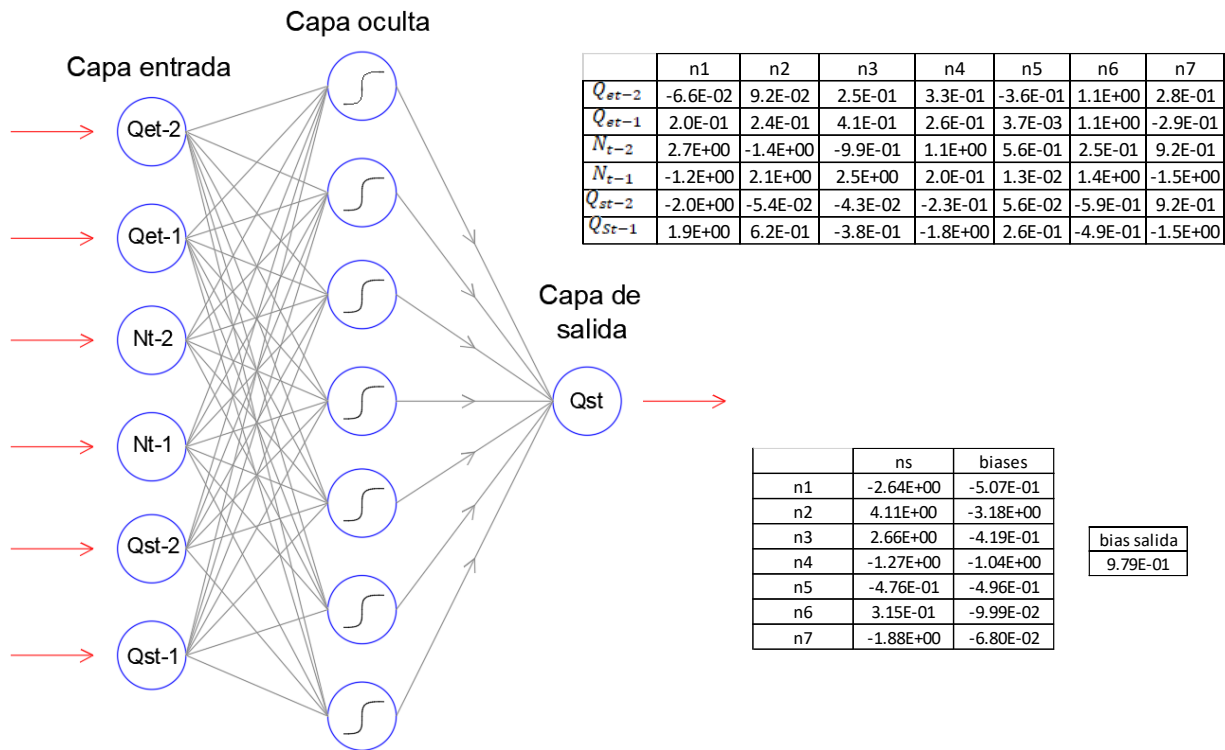


Figura 26. Configuración final de RNA para las reglas de operación actuales del embalse

En la siguiente tabla se muestra, en resumen, los valores del MSE, MAE, y la cantidad de parámetros para cada una de las configuraciones evaluadas. La figura 27 muestra el hidrograma obtenido para la serie de prueba (test) de la red de 7 neuronas.

Tabla 2. Indicadores de MSE y MAE para las diferentes configuraciones de RNA evaluadas

Número de Neuronas	MSE	MAE	Cantidad de parámetros
4	0.0135	0.0580	33
5	0.0142	0.0550	41
6	0.0125	0.0599	49
7	0.0126	0.0537	57
8	0.0145	0.0596	65
9	0.0139	0.0596	73
10	0.0131	0.0558	81




Figura 27. Hidrograma de caudales de descarga del embalse obtenido para el test de validación del modelo final de RNA de 7 Neuronas

4.4.3 Modelos de operación

En el presente estudio, por modelo de operación se entiende el proceso de simulación del embalse para cada paso de tiempo del periodo de análisis mediante la ecuación de la conservación de la masa, considerando los componentes y restricciones físicas del sistema y calculando los caudales de descarga controlados mediante reglas de operación definidas por funciones matemáticas.

Se plantearon entonces, tres modelos de operación para el embalse considerando tres funciones matemáticas de aproximación

1. Redes Neuronales artificiales (RNA)

2. Redes Neuronales con funciones de Base Radial (RBR)

3. Funciones lineales.

Cada una de las tres funciones anteriores tiene por entradas las mismas que fueron definidas en el paso 1 (análisis de información) y mediante estas funciones, básicamente se calcula los caudales controlados de descarga del embalse, es decir, aquellos que pueden realizarse por turbinado o mediante las válvulas de desfogue de fondo.

Para la elaboración de los modelos de operación se emplearon los datos de la batimetría del embalse, las series de caudales de entrada para el periodo de análisis 2009-2019, los datos de evaporación mensual media multianual de la zona y la función de descarga del vertedero elaborada a partir del nivel del embalse. Para calcular el volumen del embalse para cada paso de tiempo (escala diaria) se emplea la ecuación de balance hídrico descrita a continuación:

$$s_{t+1} = s_t + V_{et} - V_{st} - EVP$$

En donde s_{t+1} es el volumen de almacenamiento del embalse para el siguiente paso de tiempo; s_t es el volumen de almacenamiento del embalse para el periodo actual. V_{et} es el volumen de entrada del embalse para el periodo actual; V_{st} corresponde al volumen de salida calculado para el periodo actual; EVP corresponde al volumen de evaporación para el periodo actual.

El modelo de operación comienza con un valor inicial del volumen de almacenamiento del embalse con el cual se estima su nivel y área superficial empleando la batimetría. Los caudales de descarga controlados se calculan mediante las funciones de aproximación, ya sea Redes Neuronales Artificiales, Redes de Base Radial o Funciones lineales (estas funciones serán las que más adelante se optimizarán en el paso 3 de la metodología). Para evitar que estos valores se encuentren fuera de los rangos de operación del embalse se introducen las restricciones para descarga mínima y descarga máxima. La descarga mínima se fija como el Caudal de salida que es excedido el 95 % de las veces durante el periodo de análisis (Q95), el cual corresponde

a un valor de 7.5 m³/s. Por su parte la descarga máxima se fija como la suma entre la capacidad máxima de salida por turbinado que equivale a un valor de 30 m³/s y la capacidad máxima de salida por las válvulas de desfogue de fondo que equivale a 164 m³/s (82 m³/s cada una), resultando en una capacidad máxima controlada de 194 m³/s.

De igual forma se fijan los límites de operación del embalse según sus niveles (descargas controladas), estableciendo que para niveles iguales o inferiores a 70 m.s.n.m las descargas sean iguales al Q95, es decir, 7.5 m³/s. El nivel máximo de operación se fija en 87.5 m.s.n.m el cual corresponde a un 1 m por encima de la cota de la cresta del vertedero, así entonces para valores superiores a este nivel la descarga controlada se fijará como el caudal máximo de evacuación de las turbinas (30 m³/s).

Una vez definidas los caudales de salida controlados, se verifica si se producen descargas por vertimiento, por lo tanto, si el nivel del embalse es inferior a 86.5 m.s.n.m se entiende que no hay vertimiento, por otra parte, si el nivel supera esta cota se estima el caudal vertido mediante el uso de una función lineal calibrada en función de la altura sobre la cresta del vertedero. Las descargas totales del embalse Q_{st} serán entonces la suma de las descargas controladas más las descargas por vertimiento. La función del vertedero fue calibrada mediante los registros reales de descargas por vertimiento del embalse y los respectivos niveles presentados, lo anterior fue realizado usando la herramienta de ecuaciones polinómicas de Microsoft Excel para líneas de tendencia. La ecuación obtenida se presenta a continuación.

$$Q_{ver} = 11.44H^4 - 70.09H^3 + 122.96H^2 + 50.84H + 1.31$$

Donde Q_{ver} es el caudal de salida por el vertedero del embalse en metros cúbicos por segundo. Y H es la altura de la lámina de agua sobre la cresta del vertedero del embalse en metros.

Para la estimación de las pérdidas por evaporación se utilizan los valores de evaporación media mensual multianual registrados en la zona. Estos valores se obtienen de la estación climatológica JUMA-BONAO proporcionada por el Instituto Nacional de Recursos Hidráulicos INDRHI empleando los valores mensuales de evaporación del tanque A para todos los años de registro, promediando para cada mes los valores registrados en todos los años. Este valor se multiplica por el área superficial de la lámina de agua del embalse obtenido de la batimetría para conocer el volumen evaporado en cada paso de tiempo. En la figura 28 se presentan los valores de evaporación media mensual multianual tomadas para el cálculo de la evaporación del embalse. La relación del nivel del embalse y el área superficial se muestra en la figura 29.




Figura 28. Evaporación media mensual multianual para la zona de estudio.




Figura 29. Relación Nivel vs Superficie del embalse de Hatillo.

Una vez conocidos todos los valores de las entradas y salidas del embalse para el paso de operación actual t , se realiza el balance hídrico para conocer el volumen resultante para el siguiente paso de tiempo $t + 1$. El proceso se repite hasta llegar al último paso del periodo de análisis T .

El flujograma de los modelos de operación se resume en la figura 30, los cuales fueron escritos en lenguaje Python.

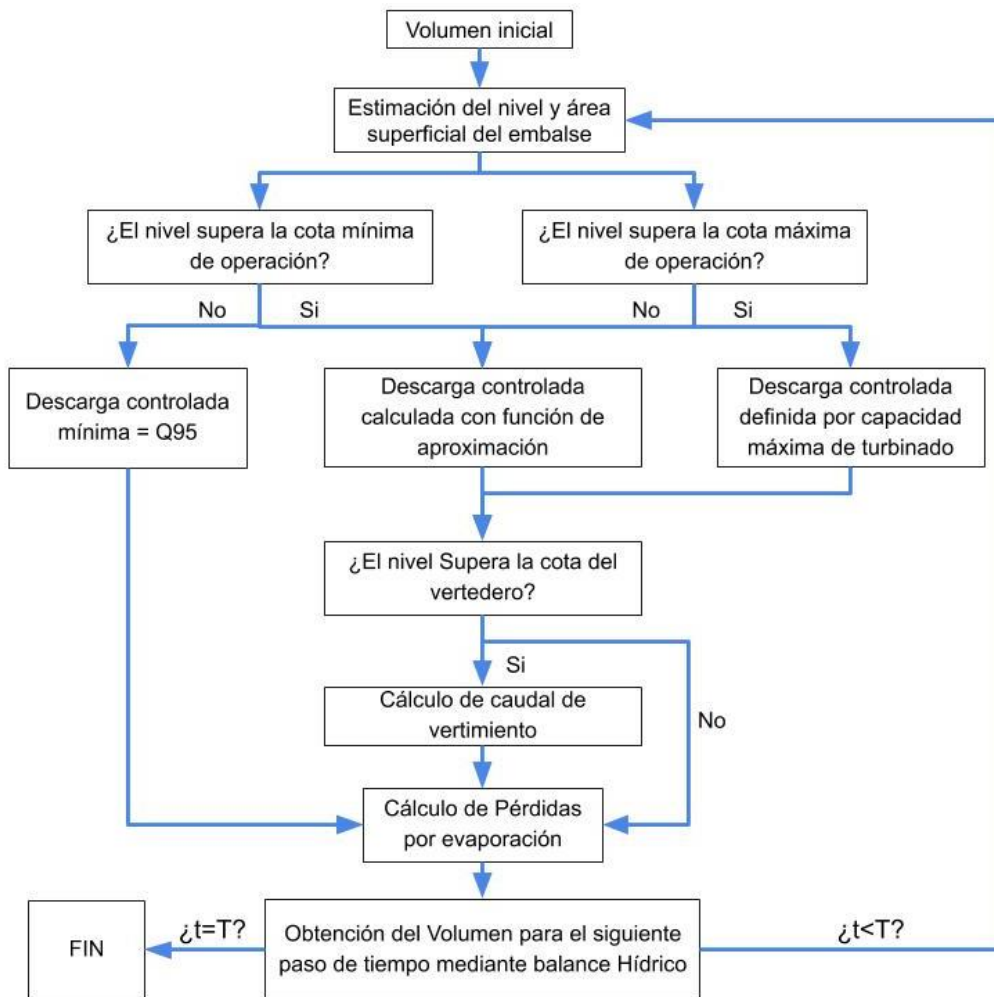


Figura 30. Flujograma de los modelos de operación construidos para el embalse de Hatillo.

4.4.3.1 Funciones de aproximación

Como se mencionó anteriormente las funciones de aproximación simulan las descargas controladas del embalse para cada paso de tiempo. Cada una de las funciones sirven de base para los modelos de operación, a continuación, se describen cada una de ellas:

Redes neuronales artificiales

Para determinar las descargas controladas del embalse se utilizan funciones de aproximación con Redes Neuronales artificiales (RNA) ya que son modelos que permiten una alta flexibilidad en su forma (Giuliani, Castelletti, Pianosi, Mason, & Reed, 2016), es decir, pueden generar patrones, formas o señales complejas que normalmente no pueden ser construidas por otras funciones.

Para el modelo de operación construido con funciones de RNA se utilizó la misma configuración de las Redes de aprendizaje de la sección 4.4.2 (Identificación de las reglas de operación actuales del embalse), es decir, PMC de tres niveles (una capa oculta), función de activación sigmoide y las variables de entrada Q_{et-2} , Q_{et-1} , N_{t-2} , N_{t-1} , Q_{st-2} y Q_{st-1} son estandarizadas empleando el método de puntuación estándar. Las funciones de Redes Neuronales empleadas en los modelos de operación se pueden expresar de la siguiente forma:

$$u_t = f(I_t)$$

$$u_t = f(Q_{et-2}, Q_{et-1}, N_{t-2}, N_{t-1}, Q_{st-2}, Q_{st-1})$$

$$u_t = a + \sum_{i=1}^N b_i \psi_i(I_t \cdot c_i + d_i)$$

$$\psi_i = \frac{1}{(1 + e^{-(I_t \cdot c_i + d_i)})}$$

Donde u_t es el valor de la descarga controlada en el tiempo t ; N es el número de neuronas; $\psi(\cdot)$ es la función sigmoide para la activación de cada neurona, es decir, la función sigmoide, I_t es el Vector de entradas de la red neuronal artificial;

$I_t = Q_{et-2}, Q_{et-1}, N_{t-2}, N_{t-1}, Q_{st-2}, Q_{st-1}$; a, b_i, c_i, d_i son los parámetros de la red neuronal artificial (pesos de conexiones y sesgos), siendo M el número de variables de entrada al modelo.

Finalmente, para el modelo de operación con funciones de RNA se construyeron 3 configuraciones empleando 4, 6 y 7 neuronas en la capa oculta. Los parámetros de las funciones, es decir los pesos de las conexiones y sesgos inicialmente son generados aleatoriamente para un dominio $-1 \leq a, b_i, c_i, d_i \leq 1$. La figura 31 presenta las configuraciones de RNA empleadas en el modelo operacional.

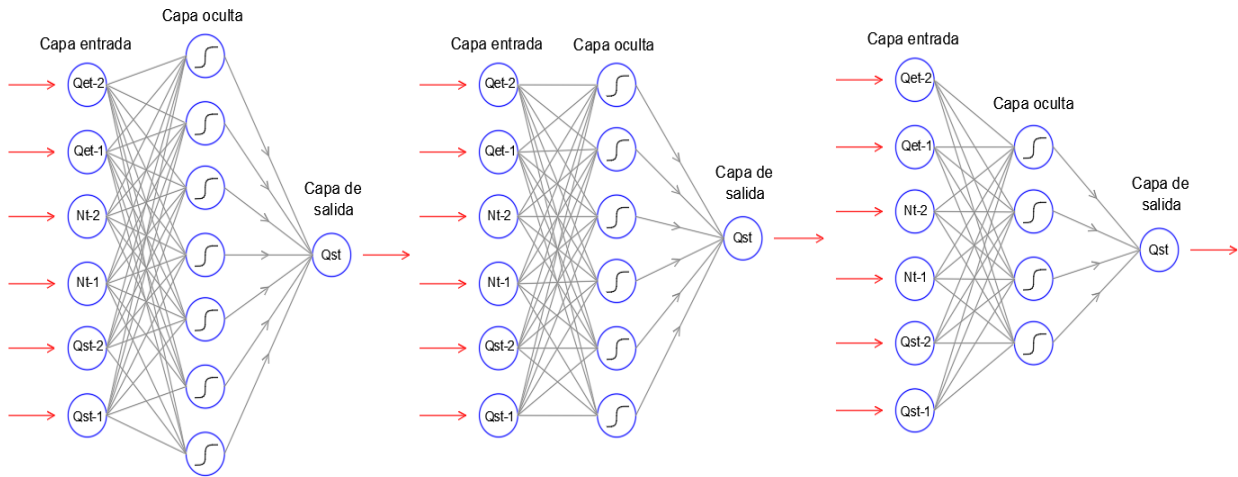


Figura 31. Configuración de las RNA propuestas para los modelos de operación.

En la figura anterior cada línea gris representa un parámetro de peso o conexión entre las neuronas, y cada neurona de la capa oculta tiene un parámetro sesgo d_i . La neurona de salida también tiene un sesgo a . Por lo tanto, el número total de parámetros, es decir, pesos de conexiones y sesgos es $n_\theta = N(M + 2) + 1$, estos parámetros serán las variables de decisión para los algoritmos de optimización del próximo paso de la metodología (Paso 4). Siendo M el número de variables de entrada al modelo.

Redes de base radial

Los modelos de operación construidos con funciones de Redes de Base Radial (RBR) tienen una configuración similar a las RNA. Sin embargo, la diferencia radica en que en las RBR en lugar de usar funciones de activación (p.ej. la función sigmoide

en RNA), utilizan una función de base radial que sustituye a las neuronas (en lugar de neuronas en RBR se tienen Bases). La función de base radial empleada se muestra a continuación:

$$\varphi_i(I_t) = \exp \left[- \sum_{j=1}^M \frac{[(I_t)_j - c_{j,i}]^2}{b_{j,i}^2} \right]$$

Donde I_t es el vector de entradas de la red neuronal artificial; M es el número de entradas I_t ; c_i , b_i son los vectores del centro y el radio de la RBR, cada una de dimensión M ; Así entonces, la salida de la RBF se puede expresar como:

$$u_t = \sum_{i=1}^N w_i \varphi_i(I_t)$$

Donde u_t es el valor de la descarga controlada en el tiempo t ; N es el número de RBR $\varphi(\cdot)$; y w_i es el parámetro de peso o conexión de la i th RBR.

Los parámetros de la RBR son entonces, c_i , b_i de cada Base y w_i para la conexión. El número total de parámetros será entonces: $n_\theta = N(2M + 1)$.

Al igual que para los modelos de operación con RNA, para RBR se construyeron 3 configuraciones de 4, 6 y 7 Bases. Los parámetros de las funciones, es decir los pesos de las conexiones, centro y radio de cada Base, inicialmente, son generados aleatoriamente para un dominio $-10 \leq b_i, c_i, w_i \leq 10$, El número total de parámetros será entonces: $n_\theta = N(2M + 1)$, estos parámetros serán las variables de decisión para los algoritmos de optimización del próximo paso de la metodología (Paso 4). La figura 32 presenta las configuraciones de RBR empleadas para los modelos de operación.




Figura 32. Configuración de las RBR para modelos de operación.

Función lineal

Finalmente, se propone un modelo de operación construido con una función lineal simple, únicamente con el propósito de evaluar la linealidad de las reglas de operación del embalse y compararlo con los demás modelos operacionales propuestos. La función lineal empleada se presenta a continuación:

$$u_t = \beta_0 + \beta_1 Q_{et-2} + \beta_2 Q_{et-1} + \beta_3 N_{t-2} + \beta_4 N_{t-1} + \beta_5 Q_{st-2} + \beta_6 Q_{st-1}$$

Donde u_t Es el valor de la descarga controlada en el tiempo t . $Q_{et-2}, Q_{et-1}, N_{t-2}, N_{t-1}, Q_{st-2}, Q_{st-1}$, son los datos de entrada (Ver paso 1) y $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6$ son los parámetros de la función, los cuales inicialmente son generados de manera aleatoria para un rango entre -5 y 5. Estos parámetros serán las variables de decisión de los algoritmos de optimización del próximo paso de la metodología.

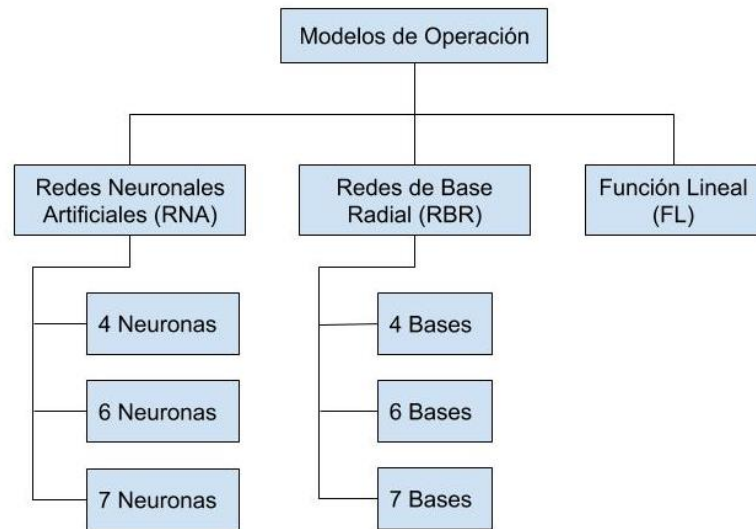


Figura 33. Modelos de operación propuestos para el embalse de Hatillo.

Los códigos en Python de los modelos de operación se presentan en el anexo 1.

4.4.4 Estimación de la demanda de agua para riego

Uno de los propósitos del embalse de Hatillo es el suministro de agua para riego en el bajo Yuna, especialmente para el cultivo de arroz, el cual es el principal cultivo alimenticio de la República Dominicana (Moquete, 2004). El embalse suministra agua para el riego de aproximadamente 27000 Ha de cultivos. Para la estimación de la demanda de riego es importante conocer además de la superficie de riego, los ciclos de los cultivos, las épocas de siembra, los coeficientes del cultivo y los factores climáticos de la zona. Para efectos del presente estudio, y conociendo que el cultivo de arroz además de ser el que abarca la mayor cantidad de superficie en la zona de estudio, es el cultivo que necesita mayor cantidad de agua, la demanda de riego total fue estimada a partir de los requerimientos para la producción del cultivo de arroz. Teniendo en cuenta el patrón estacional que rige el ciclo de producción del

arroz, el cual generalmente abarca dos cosechas anuales, se calculó la demanda de riego mensual requerida para un año típico correspondiente al periodo de análisis, es decir demandas mensuales multianuales para el periodo 2009-2019. Por lo tanto, para cada año se repiten los mismos valores de demanda de riego en cada mes. Dicha demanda fue convertida en caudales diarios para ser incorporados a los modelos de operación.

4.4.4.1 Determinación del área de riego

Para la determinación del área de riego fue necesario emplear imágenes Raster obtenidas de las misiones satelitales Sentinel II y LandSat que abarcaran el periodo de análisis (2009-2019); mediante la ayuda de herramientas computacionales de programas SIG se obtuvo la cobertura del cultivo de arroz en el bajo Yuna. En la figura 34 se muestra la superficie de cultivo que se abastece del embalse.

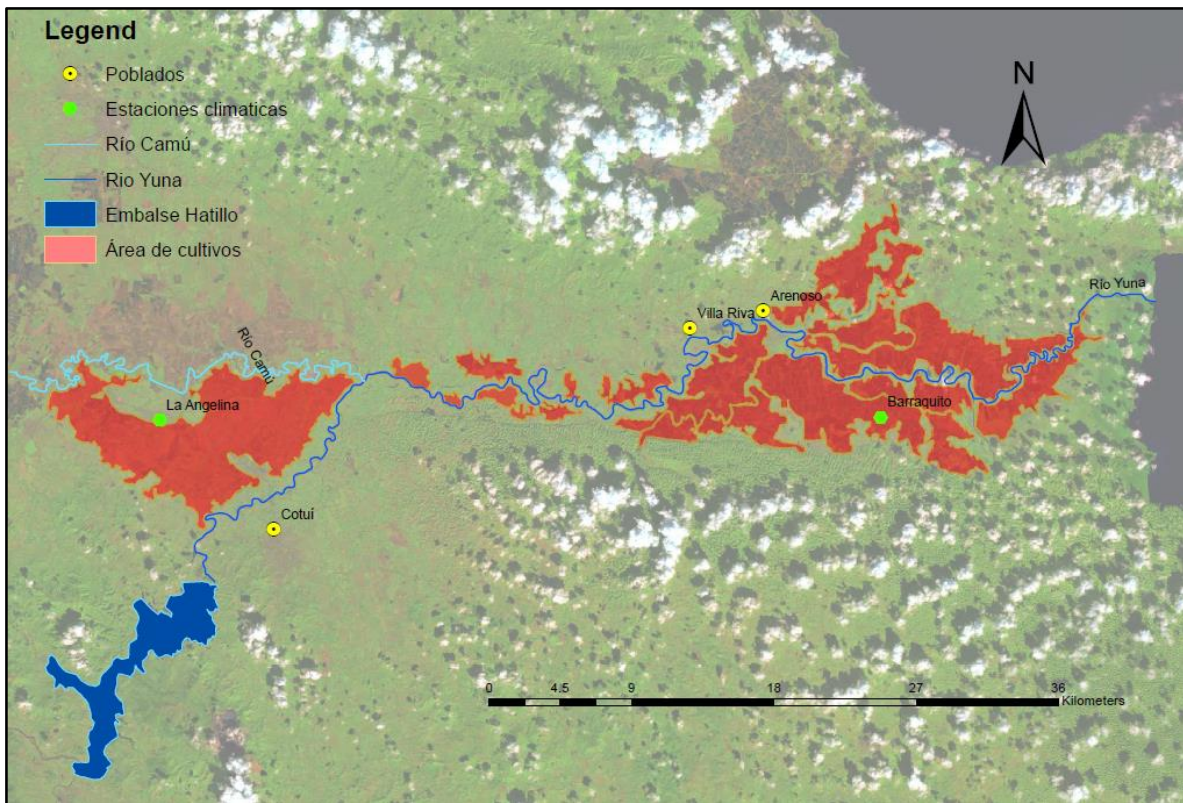


Figura 34. Área de cultivos alimentados por Hatillo en la zona del Bajo Yuna.



Figura 35. Imagen Satelital del Área de cultivos en la zona del Bajo Yuna.

4.4.4.2 Determinación de los caudales de riego

Para determinar los caudales de riego se utilizó el software CropWat 8.0 desarrollado por la FAO, el cual requiere de información climática, precipitaciones e información del cultivo. El método empleado por el programa para el cálculo de la Evapotranspiración de referencia ETo es el de Penman-Monteith, para lo cual se introdujeron datos de temperatura, porcentaje de humedad, velocidad del viento y horas de brillo, datos que fueron obtenidos de la información histórica de las estaciones climatológicas Barraquita (1814) y la Angelina (1815) proporcionados por el Instituto Nacional de Recursos Hidráulicos INDRHI. Los anteriores datos fueron introducidos al programa como datos medios mensuales multianuales. De igual manera, se introdujeron los datos de precipitaciones medias mensuales multianuales obtenidos para la zona de estudio empleando los registros de las mismas estaciones mencionadas previamente: Barraquita (1814) y la Angelina (1815).

En República Dominicana se tienen dos periodos de siembra durante el año, la primera que es la de primavera, que se realiza desde diciembre hasta abril, y la segunda que es la de invierno, que abarca los meses de junio, julio y agosto (Moquete, 2004). Para los coeficientes de cultivo y duración de la etapa de crecimiento se emplearon los datos de referencia de la FAO (FAO, 2006). Las demandas de agua para riego obtenidas por el programa se presentan en la tabla 3. Para cada paso de tiempo del modelo operacional se calcula si existe déficit o no. Para la estimación del déficit de agua se considera un caudal adicional que corresponde al Q95 o el caudal de descarga que fue excedido el 95% de las veces para el periodo de análisis 2009-2019, lo anterior para considerar un caudal remanente a considerar en el cálculo utilizando la función objetivo de minimizar déficits en el suministro de agua.

Tabla 3. Demanda de agua para riego Bajo Yuna, embalse de Hatillo.

MES	La Angelina	Barraquito	Total
1	9.63	8.94	18.57
2	4.51	5.11	9.62
3	5.73	6.82	12.55
4	4.10	7.24	11.34
5	5.94	9.80	15.74
6	5.53	15.33	20.86
7	9.22	11.50	20.72
8	7.78	7.67	15.45
9	3.89	4.26	8.15
10	2.87	2.56	5.42
11	3.48	7.24	10.72
12	1.84	8.52	10.36

4.4.5 Cálculo de la potencia generada por turbinado

Adicional al suministro de agua para riego y al control de inundaciones, el embalse de Hatillo tiene una central hidroeléctrica, por lo tanto, la potencia generada por turbinado se calcula para cada paso de tiempo de los modelos de operación mediante la siguiente expresión:

$$P_t = \eta \gamma H_t q_t^{turb}$$

Donde η es la eficiencia de la turbina, γ es el peso específico de agua (9.81 m³/s), H_t es la cabeza hidráulica (que depende del nivel del agua del embalse y el nivel del eje de la turbina).

El caudal turbinado q_t^{turb} se estima en función del caudal de descarga controlado del embalse, si este último es mayor que la capacidad máxima de turbinado, el caudal turbinado se toma igual a esta capacidad, de lo contrario el caudal turbinado es equivalente a la descarga controlada del embalse $q_t^{turb} = Q_{st}$.

La eficiencia de la turbina se define en función del caudal turbinado, dicha eficiencia es tomada del gráfico de eficiencias típicas para turbinas (Ferrada, 2012), de donde se toma la curva para la turbina Francis.




Figura 36. Eficiencia de las turbinas en función del caudal de flujo

En resumen, fueron generados siete modelos de operación, que consisten en tres modelos con redes neuronales artificiales, tres modelos con Redes de Base Radial y uno con función lineal. Cada uno de estos modelos de operación serán optimizados mediante JMETALPY en la siguiente sección.

4.4.6 Optimización

En la presente sección se presentan los procedimientos realizados para la optimización de los modelos operacionales del embalse de Hatillo, comenzando con el acople de los mismos a los algoritmos de optimización utilizando el módulo

JMETALPY de Python, posteriormente la elección de los parámetros y aplicación de los algoritmos y por último la obtención de los frentes de Pareto.

4.4.6.1 Acople de modelos de operación a JMETALPY

Los modelos de operación elaborados en la sección anterior son ensamblados a JMETALPY, el cual es un entorno de optimización multiobjetivo desarrollado en Python. Los códigos son insertados a JMETALPY como una subclase perteneciente a la clase principal de problemas de tipo flotante (Float Problem), un módulo que se encuentra dentro del núcleo del paquete. En la figura 37 se presenta un ejemplo para la introducción de nuevos problemas al entorno JMETALPY (Benítez-Hidalgo, Nebro, García-Nieto, & Oregi, December 2019):

```
from jmetal.algorithm.multiobjective import NSGAIID
from jmetal.operator import SBXCrossover, PolynomialMutation
from jmetal.problem import ZDT1
from jmetal.util.termination_criterion import StoppingByEvaluations

problem = ZDT1()

algorithm = NSGAIID(
    problem=problem,
    population_size=100,
    offspring_population_size=100,
    mutation=PolynomialMutation(probability=1.0 / problem.number_of_variables, distribution_index=20),
    crossover=SBXCrossover(probability=1.0, distribution_index=20),
    termination_criterion=StoppingByEvaluations(max_evaluations=25000)
)

algorithm.run()
```

Figura 37. introducción de problemas de optimización al entorno JMETALPY

De la figura anterior, se observa que el problema a ser optimizado es almacenado en una variable llamada “problema”. Para la introducción de los modelos operacionales se debe sustituir la clase ZDT1 (el cual es el ejemplo) por el modelo

de operación. El nombre de los parámetros que corresponden a las variables de decisión del problema se reemplazan según el nombre de las variables que reconoce el optimizador (solution.variables[])

4.4.6.2 Funciones objetivo

Como se mencionó antes, el objetivo del presente estudio es encontrar reglas de operación para el embalse de Hatillo que permitan reducir las inundaciones aguas abajo en el Bajo Yuna, sin afectar considerablemente los demás propósitos, por lo cual, este problema se debe abordar bajo un enfoque multiobjetivo. Las funciones objetivo que entonces se consideran para los tres propósitos mencionados se presentan a continuación:

Control de inundaciones

$$FO1 = J_{min}^{flo} = \sum_{t=0}^T (g_t^{flo})$$

$$g_t^{flo} = \begin{cases} 0 & \text{si } h_t^{HN} \leq \bar{q} \\ (q_t^{ST} - \bar{q})^2 & \text{de otra manera} \end{cases}$$

En donde q_t^{ST} es la descarga de agua del embalse, \bar{q} es el caudal de descarga límite de inundación, g_t^{flo} es la función de poder para inundación en el tiempo t . $FO1$ es la función objetivo para control de inundaciones.

Debido a que no se tiene información de los valores de caudales de descarga del embalse que puntualmente generan inundaciones o afectaciones aguas abajo, con el fin de tener un margen conservador y minimizar principalmente los picos de los hidrogramas, en el presente estudio se propone fijar un caudal límite de inundación \bar{q} promediando todos los valores de descarga diarios del embalse Q_i que

excedieron el caudal de descarga medio anual Q_{an_medio} , tal como se han propuesto en otros estudios para la operación óptima de embalses durante temporadas de inundación (Saavedra, Koike, Yang, & Yang, 2010).

$$\bar{q} = \sum_{i=1}^N \frac{Q_i}{n}; \quad Q_i > Q_{an_medio}$$

Donde n es el número de datos de caudales de descarga.

Suministro de agua para riego

$$FO2 = J_{min}^{hyd} = \sum_{t=0}^T (g_t^{sum})$$

$$g_t^{sum} = \begin{cases} 0 & \text{si } q_t^{ST} > w_t \\ (w_t - q_t^{ST})^2 & \text{de otra manera} \end{cases}$$

En donde w_t es la demanda diaria de agua para riego, q_t^{ST} es el suministro o la descarga del embalse, g_t^{sum} es la función de poder para suministro de agua en el paso de tiempo t . T es el total de los pasos de tiempo evaluados. t es el periodo de tiempo de análisis actual. FO2 es la función objetivo para suministro de agua para riego.

Maximización de la potencia generada

$$FO3 = P_{max}^{ener} = \sum_{t=0}^T q_t^{turb}$$

$$q_t^{turb} = \begin{cases} 0 & \text{si } r_t \leq q^{min} \\ \min(r_t, q^{max}) & \text{de otra manera} \end{cases}$$

En donde r_{t1} es la descarga del embalse, q^{max} es la capacidad máxima de las turbinas, q^{min} es la descarga mínima a través de las turbinas. q_t^{turb} es el caudal

turbinado en el tiempo t . $F03$ es la función objetivo de maximización de la potencia generada.

4.4.6.3 Selección de los parámetros del algoritmo de optimización

Los algoritmos de optimización utilizados en el presente estudio son el NSGAI y MOEA/D, los cuales vienen incluidos dentro del entorno JMETALPY. La elección de los valores para el tamaño de la población y parámetros individuales en los algoritmos de optimización depende en gran medida del problema de optimización (Ritter, 2016). Para la elección del tamaño de la población se utilizaron pruebas de ensayo y error para varios rangos de poblaciones en donde se encontró que poblaciones superiores a 100 individuos presentaban baja convergencia para NSGA II, y para MOEA/D poblaciones superiores a 300 individuos. Por otra parte, para los demás parámetros también se realizaron pruebas de ensayo y error utilizando poblaciones pequeñas (de hasta 50 individuos) con el fin de que JMETALPY convergiera rápidamente, se tomaron como base los valores por defecto con los cuales trabajan los algoritmos. En la tabla 4, se resumen los parámetros utilizados en los algoritmos de optimización.

El proceso de optimización fue desarrollado por una computadora con 16 GB de RAM y 8 núcleos de 2.6 GHz. Los códigos JMETALPY fueron ejecutados implementando el módulo MultiprocessEvaluator el cual le permite a la máquina realizar cálculos más rápidos. Esto hace que individuos dentro de una generación (en un algoritmo de optimización) se puedan calcular de forma paralela. JMETALPY reportó para cada modelo de operación, una convergencia promedio, después de 8 horas para procesos de 10000 evaluaciones.

Tabla 4. Parámetros de los algoritmos de optimización NSGAI y MOEA/D

Algoritmo	Parámetro	Descripción	Valor
NSGAI	population_size	Tamaño de la población	100
	offspring_population_size	Tamaño de la población descendiente	100
	Mutation probability	Probabilidad de mutación	1
	distribution_index	índice de distribución	20
	Crossover probability	Probabilidad de cruce	1
	distribution_index	índice de distribución	20
MOEA/D	population_size	Tamaño de la población	300
	Crossover	CR	1
		F	0.5
	Mutation	Probabilidad	1
		índice de distribución	20
	neighbor_size	Tamaño de vecindario	20
	neighbourhood_selection_probability	Probabilidad de selección del vecindario	0.9
max_number_of_replaced_solutions	número máximo de soluciones reemplazada	2	

Mediante el módulo visualization, se obtienen los Frentes de Pareto para cada uno de las optimizaciones, es decir que para cada modelo se genera un Frente diferente y cada modelo es optimizado de manera independiente tanto por el algoritmo NSGAI como por el MOEA/D. En conclusión, fueron realizadas 14 simulaciones diferentes.

4.4.7 Selección del mejor frente de Pareto

Una vez obtenidos los Frentes de Pareto para cada modelo de operación, se evalúa cuáles tienen los mejores resultados, lo cual, visto sobre la gráfica, corresponden a los Frentes que más se aproximan al punto óptimo ideal. Una forma de hacer esto, es sobreponer todos los Frentes de Pareto en un mismo gráfico y observar cuales se acercan más al óptimo ideal. En la Figura 38 se muestra un ejemplo, en donde se

muestra un esquema tridimensional representando los Frentes de Pareto y el Punto ideal óptimo, donde la línea roja resaltada corresponde al mejor resultado debido a que se encuentra más cerca al punto óptimo ideal.

Otra forma de evaluar los resultados es mediante el uso de indicadores como el Hypervolume, el cual, es uno de los más utilizados para evaluar el desempeño de los algoritmos en problemas de optimización multiobjetivo (Guerreiro, Fonseca, & Paquete, 2005). En el presente estudio, complementariamente se calcula este indicador para cada uno de los modelos de operación con el fin de examinar con cuál de los modelos propuestos se obtiene los mejores resultados.

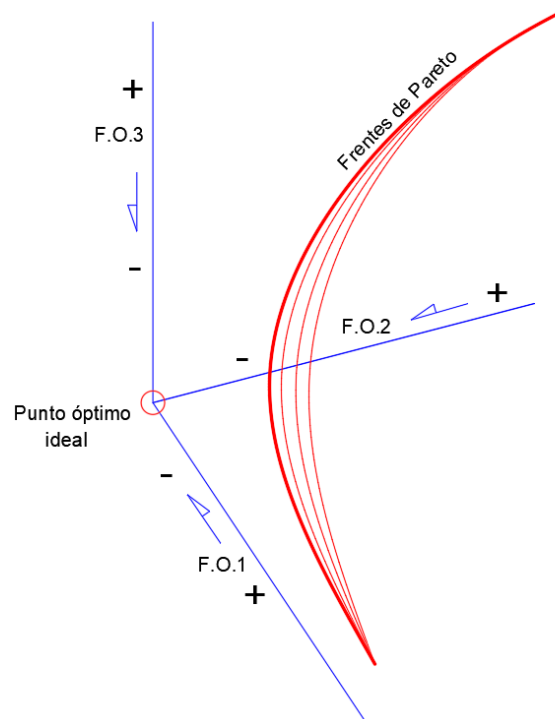


Figura 38. Esquema Espacio de Pareto tridimensional




Figura 39. Espacio de Pareto que iguala o mejora las reglas de operación actual

4.4.8 Obtención de las reglas de operación óptimas

Las reglas de operación óptimas se obtienen a partir de los puntos que componen los mejores Frentes de Pareto. Cada punto del Frente de Pareto corresponde a una regla de operación para el embalse. Entonces, inicialmente se seleccionan los puntos que igualan o mejoran la operación actual del embalse para el periodo 2009-2019. En la figura 39 se muestra a manera de ejemplo un segmento del Frente de Pareto en color verde localizado dentro del espacio que mejora o iguala la regla de operación actual. Cabe destacar, como ya se mencionó, que para el presente estudio tienen prioridad las reglas de operación que permitan reducir las magnitudes de los eventos de inundaciones en el Bajo Yuna, sin que se afecten considerablemente los demás propósitos, por lo tanto, adicionalmente se toman reglas de operación localizadas fuera de este espacio teórico, hacia el costado del objetivo de control de inundaciones.

Las reglas de operación seleccionadas son simuladas mediante los modelos de operación respectivos para verificar su desempeño y compararlas con las reglas de operación actual del embalse. Para conocer donde se sitúa la regla de operación con la que se operó el embalse durante el periodo de análisis en el frente de Pareto, únicamente se calcula el valor de los tres objetivos planteados con los datos reales de operación.

Mediante la simulación de las reglas de operación se calculan los caudales de descarga del embalse correspondientes para el periodo de estudio (2009 – 2019), los hidrogramas obtenidos son comparados con el hidrograma real registrado para el mismo periodo.

4.4.6.1 Modelo Hidráulico

Complementariamente y con el fin de poder evaluar la magnitud de las inundaciones generadas por las reglas de operación optimizadas aguas abajo del embalse se propone realizar un modelo hidráulico mediante el software de modelación bidimensional IBER. sin embargo, es de aclarar que esta simulación solo representa una aproximación para visualizar la magnitud de las manchas de inundación, sin ser considerado un análisis de detalle. Lo anterior, considerando que fue elaborado a partir de un modelo de elevación digital con una resolución espacial de 12.5 m x 12.5 m y sin contar con información de detalle de la zona.

El modelo fue creado en IBER 2.5.2, para lo cual fueron creadas tres tipos de superficies: el cauce principal o eje del río; el lecho exterior del cauce, y las planicies de inundación. Para cada una de estas superficies se le fue asignado un coeficiente de rugosidad de Manning diferente. Siendo 0.025 el cauce principal, 0.03 para el cauce exterior y 0.08 para la planicie de inundación. La malla creada es de tipo no estructurada triangular, las superficies y mallas creadas se pueden observar en las figuras 40 y 41 respectivamente.




Figura 40. Superficies de modelo hidráulico Cuenca baja Río Yuna




Figura 41. Malla para el modelo hidráulico Cuenca baja Río Yuna

Los caudales de ingresos para la simulación fueron introducidos a la salida del embalse y corresponden a los hidrogramas calculados con las reglas de operación optimizadas y para la regla de operación actual del embalse. Es importante mencionar que el modelo únicamente considera como condiciones de

contorno los caudales de descarga del embalse y como salida la desembocadura del Río Yuna en el Mar Caribe.

4.4.9 Validación de las reglas de operación seleccionadas

Además de comparar las reglas de operación optimizadas con las del manejo real del embalse, se considera determinar su validez para ser aplicadas a datos diferentes a los utilizados para los cálculos de optimización. Dado que para el análisis y optimización del embalse se emplearon la totalidad de los datos de la serie de tiempo (2009-2019), debido a la reducida cantidad de datos, se generaron series sintéticas de caudales de entrada para el embalse con el fin de simular el desempeño de las reglas de operación optimizadas que fueron seleccionadas. Además, las reglas de operación actuales también fueron simuladas empleando esta serie mediante la RNA obtenida en el paso 4.4.2.1 de la presente metodología, esto con el fin de comparar con las reglas de operación optimizadas.

4.4.9.1 Creación de serie de caudales sintéticos

La serie sintética de caudales de entrada del embalse fue elaborada con un modelo de redes neuronales artificiales empleando como base la serie de caudales de entrada real (2009-2019) e insertando un parámetro de aleatoriedad. Para la elaboración de esta serie se utilizó la metodología desarrollada por Ahmed J. & Sarma A., 2006. El modelo básicamente tiene dos componentes, el primero consiste propiamente en la Red Neuronal Artificial y el segundo corresponde al componente aleatorio. La red Neuronal busca replicar los caudales (actuales) en cada paso de tiempo registrados para la entrada del embalse; se propone una capa oculta con 4 neuronas y función de activación sigmoide; las entradas se definen como el caudal de ingreso al embalse del día anterior en cada paso de tiempo, el caudal medio mensual multianual en cada paso de tiempo y una variable climática exógena que

consiste en el indicador del niño Oceánico ONI (National Oceanic and Atmosphere Administration, 2020). Estas dos últimas variables fueron seleccionadas con el fin de otorgarle a la serie sintética un patrón estacional similar al de la serie original.

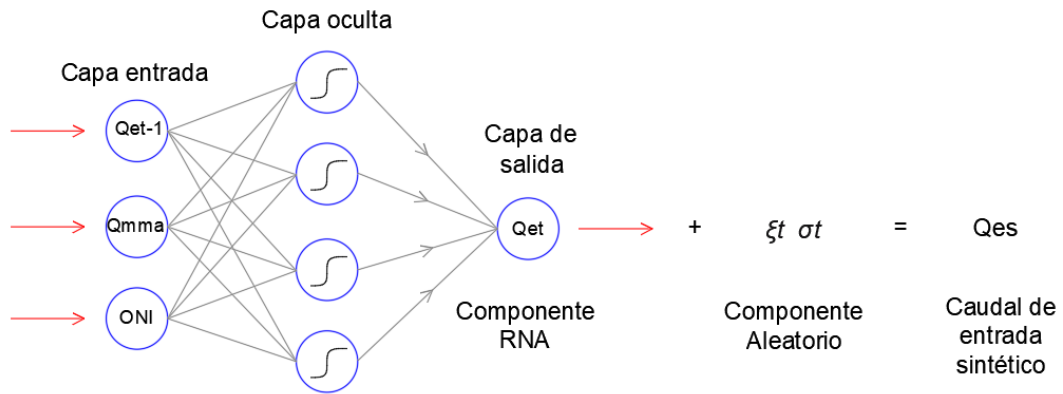


Figura 42. Componentes para la elaboración de la serie de caudales de entrada sintéticos

De la figura 42, Q_{et-1} corresponde al caudal de entrada al embalse del día anterior en cada paso de tiempo de la serie, Q_{mma} es el caudal medio mensual multianual en cada paso de tiempo, ONI es el indicador del niño Oceánico. La salida de la Red Neuronal es, por lo tanto, el valor de los caudales actuales de entrada al embalse para cada paso de tiempo Q_{et} , valor al que se le adiciona el componente aleatorio. El componente aleatorio consiste en el producto entre una variable aleatoria de promedio cero y desviación estándar uno ξ_t , y la desviación estándar de la serie de caudales observados para el mes correspondiente σ_t . Los valores obtenidos para la serie sintética se muestran en la figura 43. El tamaño de la serie es equivalente a la serie real, es decir, se generan 3840 datos.




Figura 43. Serie sintética de caudales de entrada para el embalse de Hatillo

5 Resultados y contribuciones

5.1 Frentes de Pareto

En esta sección se presentan los resultados obtenidos en el proceso de optimización de los modelos de operación para el embalse de Hatillo respecto a los tres objetivos planteados. Inicialmente se muestran los resultados obtenidos mediante el algoritmo NSGAI y los modelos de operación con funciones de aproximación de RNA, seguidamente los modelos elaborados con funciones de RBR y finalmente los modelos con funciones lineales. posteriormente se muestran los resultados utilizando el algoritmo MOEAD/D. Finalmente se hace un análisis comparativo de los diferentes métodos.

5.1.1 Modelos de operación con RNA usando NSGAI

En la figura 44 se presentan los frentes de Pareto 3D obtenidos para los modelos de operación utilizando redes neuronales artificiales y el algoritmo NSGAI. En ella se observan los resultados para los modelos de 4N, 6N y 7N, Para los cuales se observaron que varios miembros de la gráfica de Pareto igualan o superan las reglas de operación actual del embalse, observándose valores más bajos para los objetivos FO1 (Minimizar eventos de inundaciones) y FO2 (Minimizar déficit de agua para riego) y más altos para el FO3 (Maximizar generación de energía). En la tabla 5 se presenta los valores de los mejores resultados para los tres objetivos. Para la función objetivo FO3, la cual es una función de maximización se empleó una función de minimización con un factor de conversión -1, lo anterior en la medida de que los módulos utilizados por JMETALPY en el presente estudio funcionan para objetivos de minimización. Los resultados obtenidos para las tres diferentes arquitecturas evaluadas de RNA son similares, el modelo de 7N genera porcentajes de mejora levemente superiores para los tres objetivos planteados respecto a los otros modelos (4N y 6N).

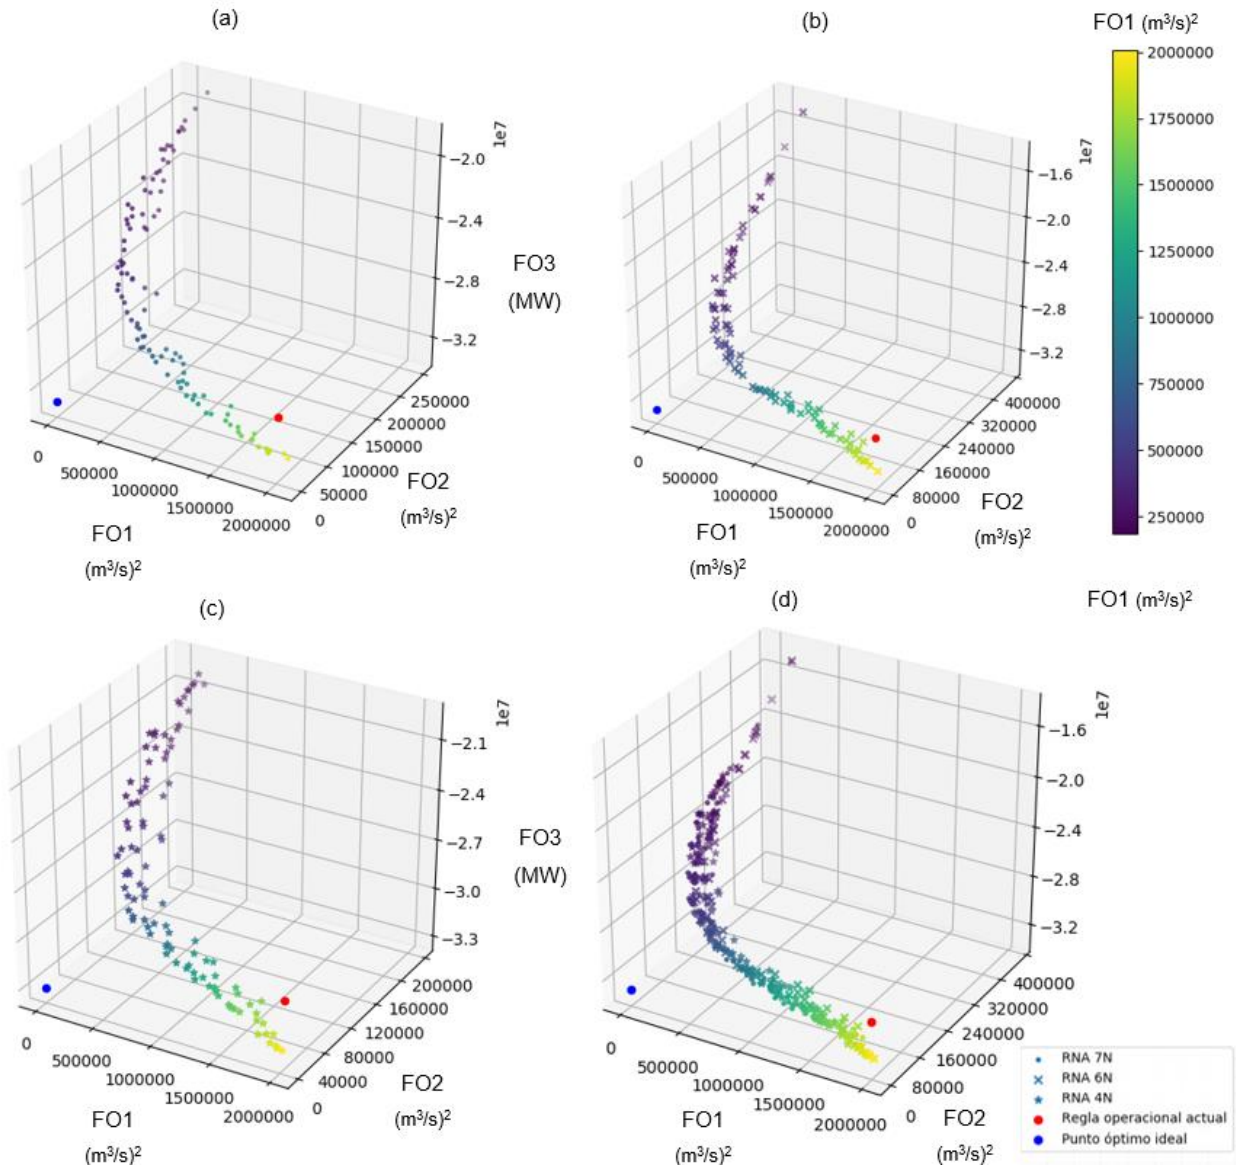


Figura 44. Frentes de Pareto para modelos con RNA usando el algoritmo NSGAI (a) Frente Pareto RNA 7N, (b) Frente Pareto RNA 6N, (c) Frente Pareto RNA 4N, (d) Frente de Pareto combinado para los 3 modelos RNA

En la figura 45 se presentan los frentes de Pareto 2D en las tres perspectivas u objetivos para los modelos operacionales con RNA (4N, 6N y 7N). La barra de color identifica el valor del objetivo no visible en los ejes de los gráficos.

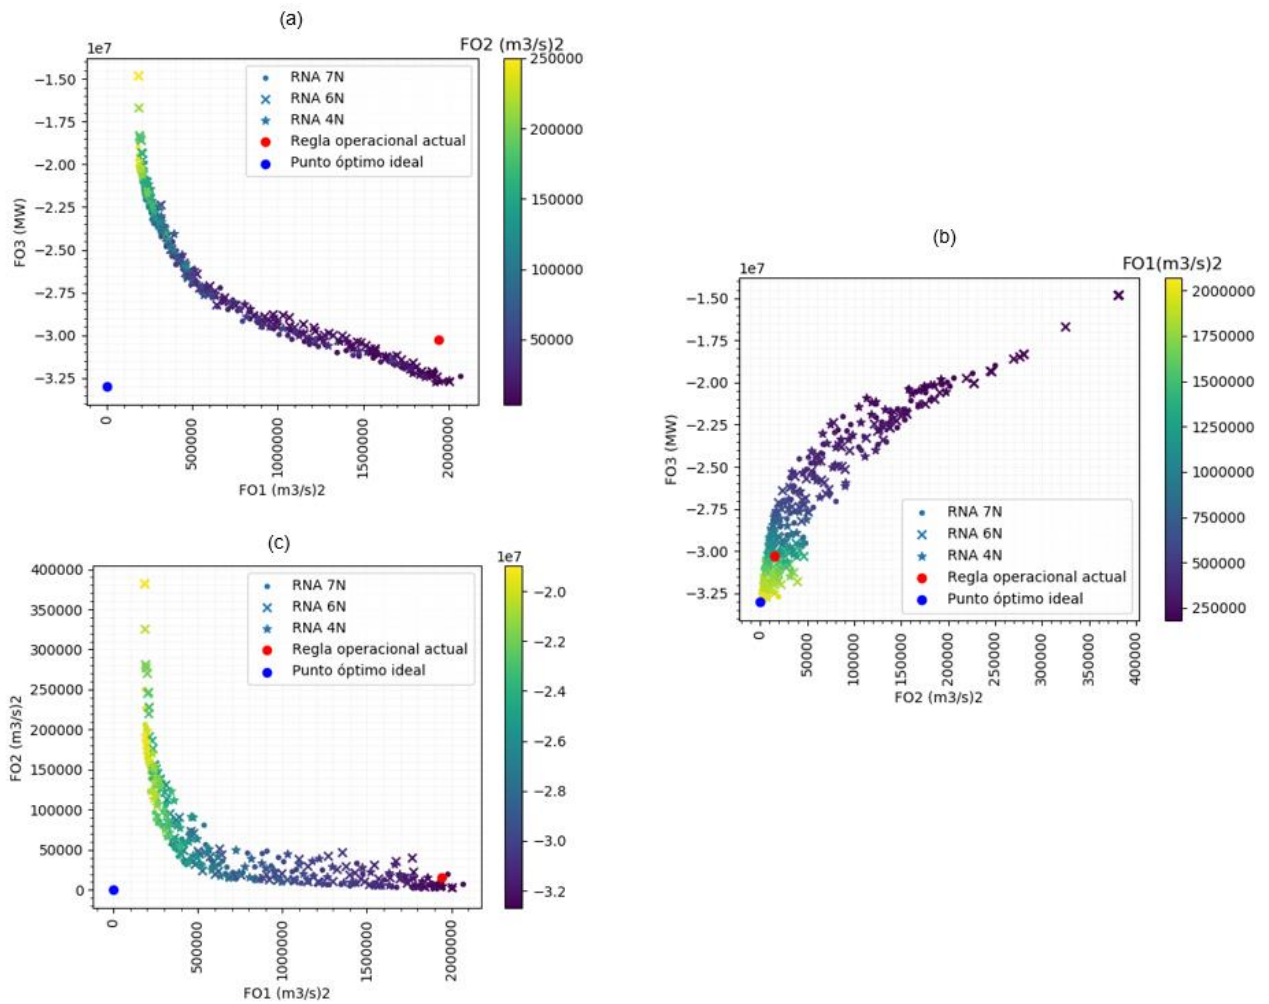


Figura 45. Frentes de Pareto 2D para modelos con RNA usando el algoritmo NSGAI. (a) FO1 vs FO3; (b) FO2 vs FO3; (c) FO1 vs FO2

Tabla 5. Mejores soluciones para cada uno de los objetivos de los modelos con RNA y el algoritmo NSGAI

MODELO OPERACIONAL	Mejores Soluciones para cada objetivo			Porcentaje mejora		
	FO1	FO2	FO3	FO1	FO2	FO3
Operación Actual	1943283	15496	-30271413	%	%	%
4 N	182483	2601	-32761446	Reduce a 9%	Reduce a 17%	Aumenta el 8%
6 N	184300	2745	-32718542	Reduce a 9%	Reduce a 18%	Aumenta el 8%
7 N	183422	2953	-32701719	Reduce a 9%	Reduce a 19%	Aumenta el 8%

Cada punto en las figuras 44 y 45 corresponde a una regla de operación obtenida por el optimizador para el manejo del embalse a partir de los tres objetivos planteados. De estos resultados se puede observar claramente el conflicto entre los objetivos de minimizar eventos de inundaciones (FO1), y los objetivos de minimizar los déficits de riego (FO2) y maximizar la generación hidroeléctrica (FO3). Esto obedece a que el embalse debe manejar niveles de operación bajos para el amortiguamiento de picos de caudales de entrada en caso de un evento extremo lo cual se contrapone con los intereses de la generación hidroeléctrica y la distribución de riego que requieren niveles de operación más altos. La tabla 5 muestra que el margen de mejora en cuanto a los objetivos de la FO1 y FO2 es considerablemente mayor a la FO3 con respecto a las políticas de operación actual.

Se puede observar también que la regla de operación actual del embalse, es decir, la regla de operación empleada para el periodo 2009-2019, la cual se encuentra identificada con un punto rojo en las figuras 44 y 45, se encuentra orientada hacia el cumplimiento de los objetivos de suministro de agua para riego y generación hidroeléctrica por lo que existe un margen considerable de mejorar el objetivo FO1.

5.1.1.1 Hidrogramas de salida generados por las Reglas de Operación usando RNA

En la figura 46 se muestra la envolvente de todos los hidrogramas de salida del embalse que generan las reglas de operación obtenidas a partir de modelos con RNA, los cuales, fueron simulados para el periodo de análisis (2009-2019). Con el fin de representar la relación de los hidrogramas con las reglas de operación que los genera se empleó una escala de color (en bandas rojo y amarillo) que corresponde con el del frente de Pareto mostrado en la figura, la cual es equivalente a los de las figuras 44 y 45 (las cuales usan un espectro de color diferente).




Figura 46. Hidrogramas de descarga del embalse para los modelos optimizados de RNA. Arriba se muestran los hidrogramas para todo el periodo de análisis, en el centro y abajo se muestran los mismos hidrogramas en detalle (dividido en dos segmentos de tiempo), el color relaciona los hidrogramas con las reglas de operación que los genera a partir de su ubicación en el frente de Pareto. El hidrograma azul representa las descargas reales efectuadas durante el periodo de análisis.

Por lo tanto, los hidrogramas que tienden al color rojo corresponden a reglas de operación que dan prioridad a la generación hidroeléctrica y al suministro de agua para riego (FO3 y FO2) y, por ende, castigan el objetivo del control de inundaciones (FO1). Por su parte, el color amarillo corresponde a reglas de operación que dan prioridad al control de inundaciones (FO1). En color azul se muestra el hidrograma de descarga real del embalse para el periodo de análisis.

Como se puede evidenciar en la Figura 46, la regla de operación real del embalse se ajusta a los hidrogramas obtenidos con reglas de operación que dan prioridad a la generación hidroeléctrica y al suministro para irrigación, prácticamente calcando las líneas de la banda roja. Se observa, que las reglas de operación que dan prioridad al control de inundaciones (Color amarillo) reducen considerablemente los picos del hidrograma correspondiente a la operación real.

En la figura 47, se muestran los resultados de las reglas de operación optimizadas indicando los tres objetivos y los caudales máximos generados para toda la serie de tiempo. Los valores son normalizados de 0 a 1 con el propósito de representar en la misma escala los resultados para los tres objetivos. La línea azul segmentada refleja la evaluación de los objetivos para la operación real del embalse en el periodo de análisis (2009-2019), la línea color cian segmentada representa el promedio de las funciones objetivo para todas las reglas de operación optimizadas.




Figura 47. Comparación de los objetivos para las reglas de operación obtenidas usando RNA

En la figura 48 se presenta con más detalle la envolvente de hidrogramas para el periodo más húmedo del tiempo de análisis, el cual va desde noviembre de 2016 hasta mayo de 2018. Así mismo, se presentan los niveles de operación para las diferentes reglas optimizadas usando RNA. La escala de color empleada representa la prioridad que se le da a la Función objetivo 1 (control de inundaciones), entre más se acerque al color rojo mayor es la penalidad al objetivo, es decir, menos control de inundaciones, mientras que entre mas amarillo, se le da menos penalidad al objetivo y por lo tanto mas prioridad.




Figura 48. Simulación de Reglas de operación optimizadas usando RNA para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.

5.1.2 Modelos de operación con RBR usando NSGAI

En la figura 49 se presentan los frentes de Pareto 3D obtenidos para los modelos de operación utilizando Funciones de Base Radial y el algoritmo NSGAI. En ella se observan los resultados para los modelos de 4B, 6B y 7B, para los cuales se observaron que varios miembros de la gráfica de Pareto igualan o superan las reglas de operación actual del embalse, observándose valores más bajos para los

objetivos FO1 (Minimizar eventos de inundaciones) y FO2 (Minimizar déficit de agua para riego) y más altos para el FO3 (Maximizar generación de energía). En la tabla 6 se presentan los valores de los mejores resultados para los tres objetivos. Para la función objetivo FO3, la cual es una función de maximización se empleó una función de minimización con un factor de conversión -1, lo anterior en la medida de que los módulos utilizados por JMETALPY en el presente estudio funcionan para objetivos de minimización.

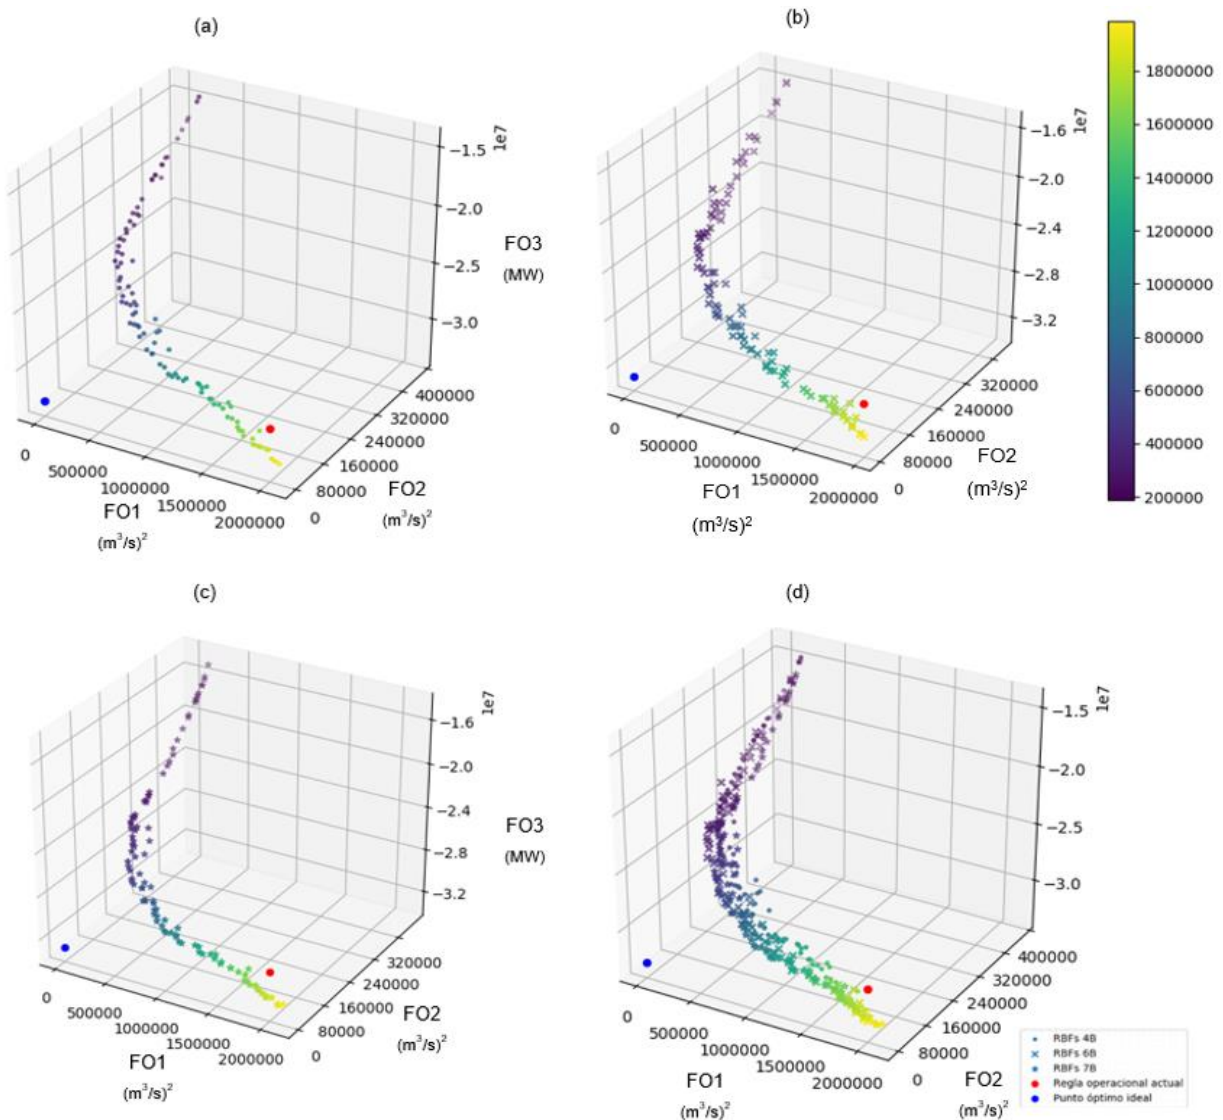


Figura 49. Frentes de Pareto para modelos con RBR usando el algoritmo NSGAI1 (a) Frente Pareto RBR 7B, (b) Frente Pareto RBR 6B, (c) Frente Pareto RBR 4B, (d) Frente de Pareto combinado para los 3 modelos RBR

En la figura 50 se presentan los frentes de Pareto 2D en las tres perspectivas u objetivos para los modelos operacionales con RBR (4B, 6B y 7B). La barra de color identifica el valor del objetivo no visible en los ejes de los gráficos.

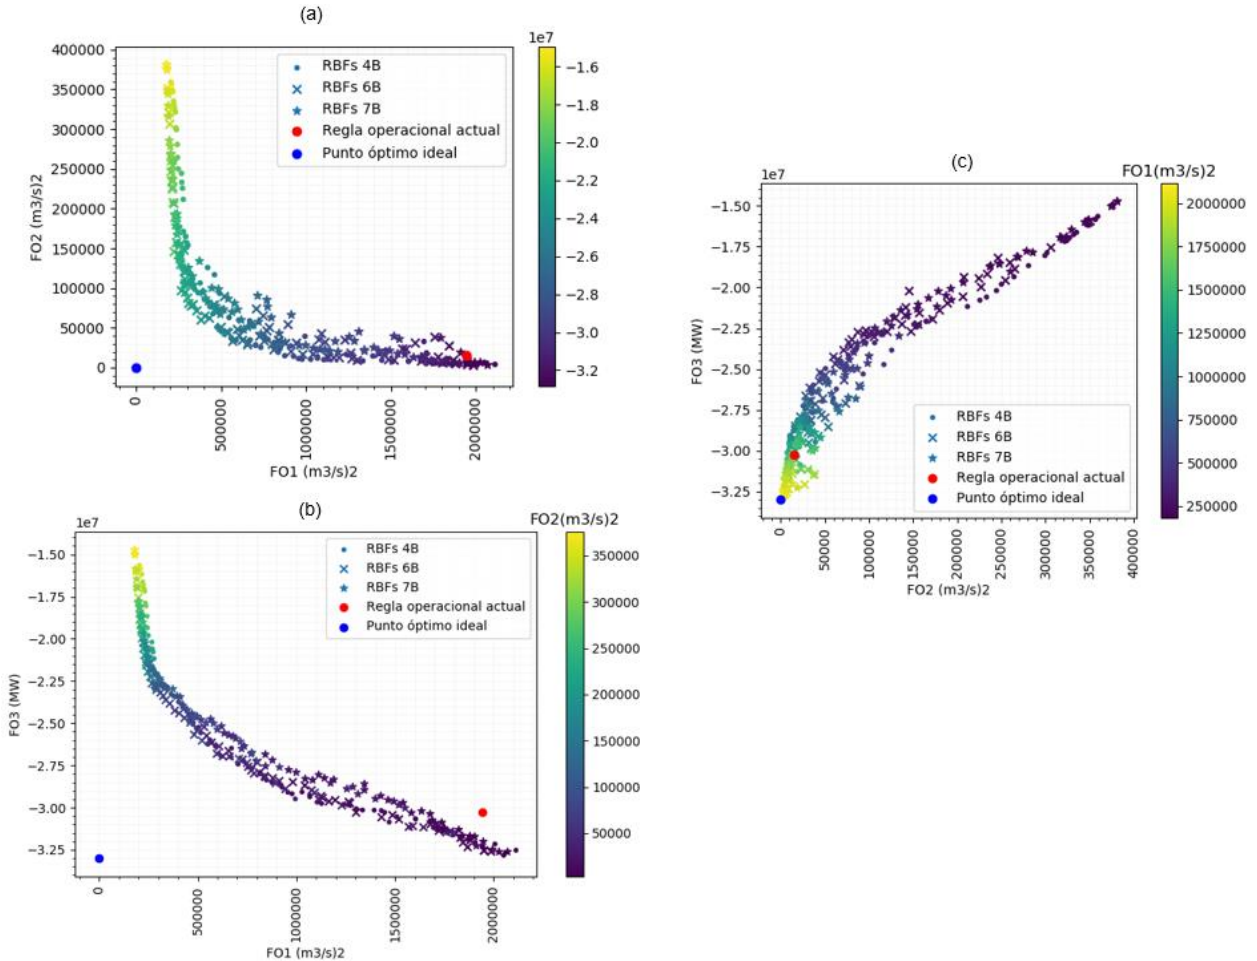


Figura 50. Frentes de Pareto 2D para modelos con RBR usando el algoritmo NSGAI (a) FO1 vs FO3, (b) FO2 vs FO, (c) FO1 vs FO2

En general, se puede observar que los gráficos de Pareto utilizando RBR se asemejan a los modelos de RNA. La tabla 6, y las figuras 49 y 50 muestran que los resultados son muy similares para las tres arquitecturas modeladas (4B, 6B y 7B).

Tabla 6. Mejores soluciones para cada uno de los objetivos de los modelos con RBR y el algoritmo NSGAI.

MODELO OPERACIONAL	Mejores Soluciones para cada objetivo			Porcentaje mejora		
	FO1	FO2	FO3	FO1	FO2	FO3
Operación Actual	1943283	15496	-30271413	%	%	%
4 B	181917	3105	-32823135	Reduce a 9%	Reduce a 20%	Aumenta a 108%
6 B	187583	2681	-32679494	Reduce a 10%	Reduce a 17%	Aumenta a 108%
7 B	180117	3184	-32618454	Reduce a 9%	Reduce a 21%	Aumenta a 108%

5.1.2.1 Hidrogramas de salida generados por las Reglas de Operación usando RBR

En la figura 51 se muestra la envolvente de todos los hidrogramas de salida del embalse que generan las reglas de operación obtenidas a partir de modelos con RBR, los cuales, fueron simulados para el periodo de análisis (2009-2019). Con el fin de representar la relación de los hidrogramas con las reglas de operación que los generó, se empleó una escala de color (en bandas rojo y amarillo) que corresponde con el del frente de Pareto mostrado en la figura. Por lo tanto, los hidrogramas que tienden al color rojo corresponden a reglas de operación que dan prioridad a la generación hidroeléctrica y al suministro de agua para riego (FO3 y FO2) y, por ende, castigan el objetivo del control de inundaciones (FO1). Por su parte, el color amarillo corresponde a reglas de operación que dan prioridad al control de inundaciones (FO1). En color azul se muestra el hidrograma de descarga real del embalse para el periodo de análisis.




Figura 51. Hidrogramas de descarga del embalse para los modelos optimizados de RBR. Arriba se muestran los hidrogramas para todo el periodo de análisis, en el centro y abajo se muestran los mismos hidrogramas en detalle (dividido en dos segmentos de tiempo), el color relaciona los hidrogramas con las reglas de operación que los genera a partir de su ubicación en el frente de Pareto. El hidrograma azul representa las descargas reales efectuadas durante el periodo de análisis.

En la figura 52, se muestran los resultados de las reglas de operación optimizadas indicando los tres objetivos y los caudales máximos generados para toda la serie de tiempo. Los valores son normalizados de 0 a 1 con el propósito de representar en la misma escala los resultados para los tres objetivos. La línea azul segmentada refleja la evaluación de los objetivos para la operación real del embalse en el periodo de análisis (2009-2019), la línea color cian segmentada representa el promedio de las funciones objetivo para todas las reglas de operación optimizadas.




Figura 52. Comparación de los objetivos para las reglas de operación obtenidas usando RBR

En la figura 53 se presenta con más detalle la envolvente de hidrogramas para el periodo más húmedo del tiempo de análisis, el cual va desde noviembre de 2016 hasta mayo de 2018. Así mismo, se presentan los niveles de operación para las diferentes reglas optimizadas usando RBR. La escala de color empleada representa la prioridad que se le da a la Función objetivo 1 (control de inundaciones), entre más se acerque al color rojo mayor es la penalidad al objetivo, es decir, menos control de inundaciones, mientras que entre mas amarillo, se le da menos penalidad al objetivo y por lo tanto mas prioridad.




Figura 53. Simulación de Reglas de operación optimizadas usando RBR para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.

5.1.3 Modelos de operación con función lineal NSGAI

En la figura 54 se presenta el frente de Pareto obtenido para el modelo operacional construido con la función lineal.

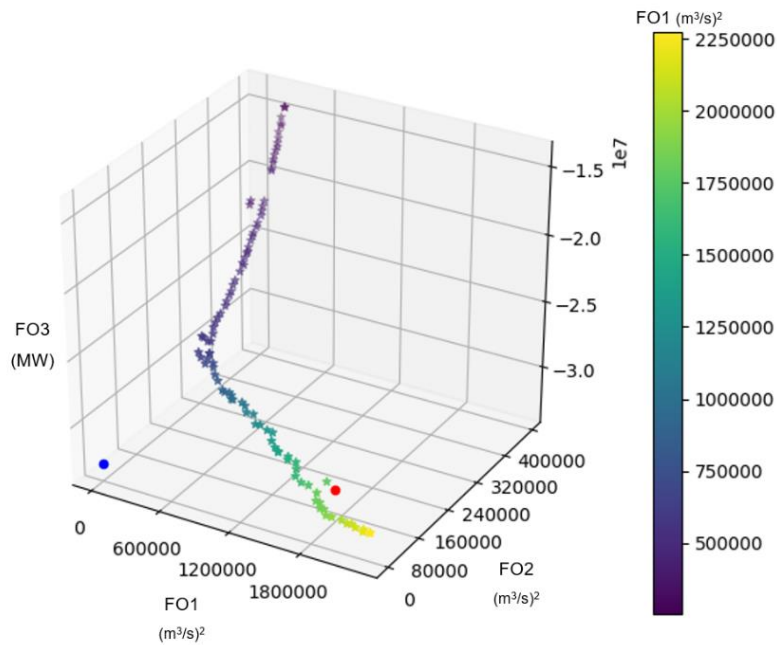


Figura 54. Frente de Pareto 3D para modelo de operación con función Lineal

En la figura 55 se presentan los frentes de Pareto 2D en las tres perspectivas u objetivos para el modelo operacional con la Función Lineal. La barra de color identifica el valor del objetivo no visible en los ejes de los gráficos.

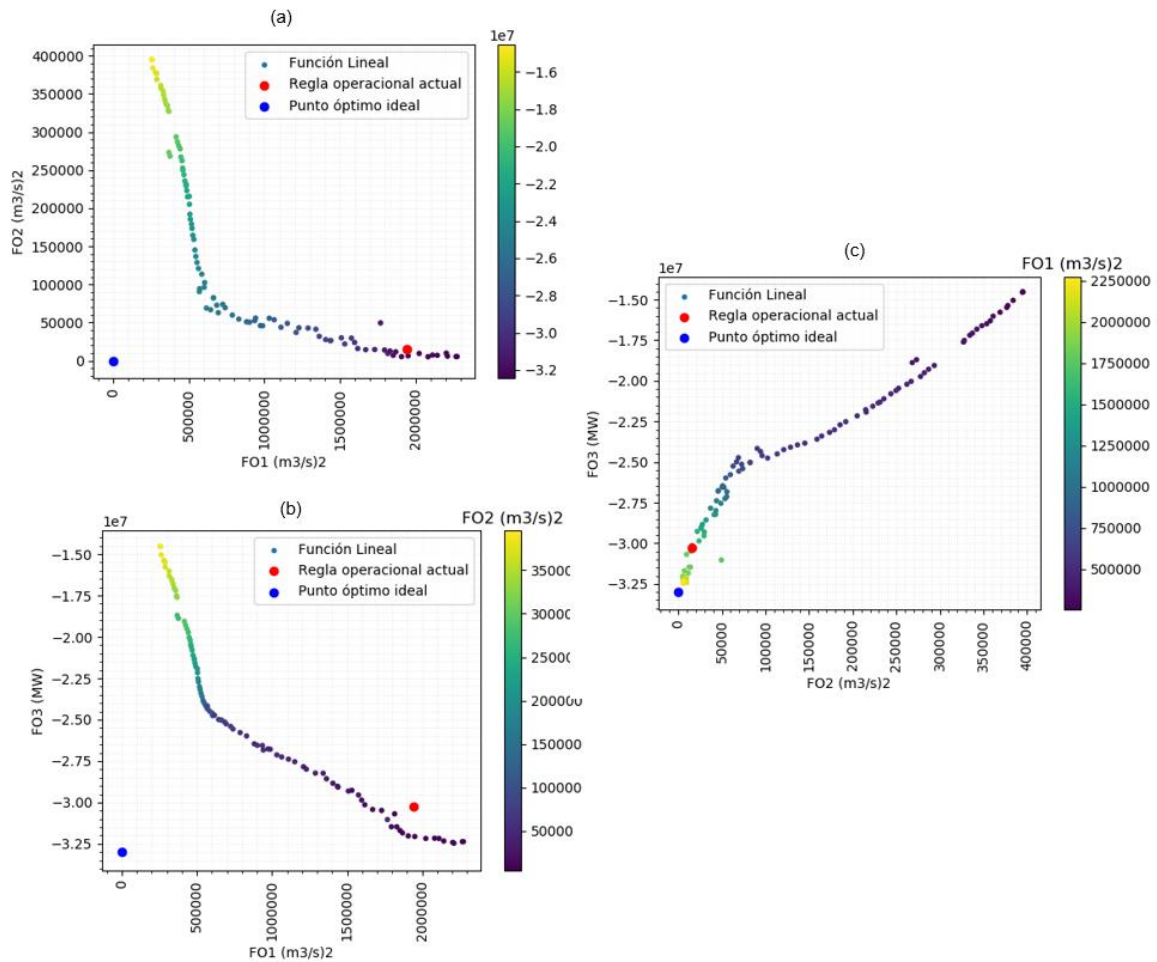


Figura 55. Frentes de Pareto para modelos de operación con FL (a) FO1 vs FO3, (b) FO2 vs FO3, (c) FO1 vs FO2

Tabla 7. Mejores soluciones para cada uno de los objetivos de los modelos con función lineal y el algoritmo NSGAI.

MODELO OPERACIONAL	Mejores Soluciones para cada objetivo			Porcentaje mejora		
	FO1	FO2	FO3	FO1	FO2	FO3
Operación Actual	1943283	15496	-30271413	%	%	%
Función Lineal	254174	5223	-32459892	Reduce a 13%	Reduce a 34%	Aumenta a 107%

5.1.3.1 Hidrogramas de salida generados por las Reglas de Operación usando función lineal

En la figura 56 se muestra la envolvente de todos los hidrogramas de salida del embalse que generan las reglas de operación obtenidas a partir del modelo con función lineal, los cuales, fueron simulados para el periodo de análisis (2009-2019). Con el fin de representar la relación de los hidrogramas con las reglas de operación que los generó, se empleó una escala de color (en bandas rojo y amarillo) que corresponde con el del frente de Pareto mostrado en la figura. Por lo tanto, los hidrogramas que tienden al color rojo corresponden a reglas de operación que dan prioridad a la generación hidroeléctrica y al suministro de agua para riego (FO3 y FO2) y, por ende, castigan el objetivo del control de inundaciones (FO1). Por su parte, el color amarillo corresponde a reglas de operación que dan prioridad al control de inundaciones (FO1). En color azul se muestra el hidrograma de descarga real del embalse para el periodo de análisis.

En la figura 57, se muestran los resultados de las reglas de operación optimizadas indicando los tres objetivos y los caudales máximos generados para toda la serie de tiempo. Los valores son normalizados de 0 a 1 con el propósito de representar en la misma escala los resultados para los tres objetivos. La línea azul segmentada refleja la evaluación de los objetivos para la operación real del embalse en el periodo de análisis (2009-2019), la línea color cian segmentada representa el promedio de las funciones objetivo para todas las reglas de operación optimizadas.




Figura 56. Hidrogramas de descarga del embalse para los modelos optimizados de Función lineal. Arriba se muestran los hidrogramas para todo el periodo de análisis, en el centro y abajo se muestran los mismos hidrogramas en detalle (dividido en dos segmentos de tiempo), el color relaciona los hidrogramas con las reglas de operación que los genera a partir de su ubicación en el frente de Pareto. El hidrograma azul representa las descargas reales efectuadas durante el periodo de análisis.




Figura 57. Comparación de los objetivos para las reglas de operación obtenidas usando función lineal

En la figura 58 se presenta con más detalle la envolvente de hidrogramas para el periodo más humedo del tiempo de análisis, el cual va desde noviembre de 2016 hasta mayo de 2018. Así mismo, se presentan los niveles de operación para las diferentes reglas optimizadas usando RNA. La escala de color empleada representa la prioridad que se le da a la Función objetivo 1 (control de inundaciones), entre más se acerque al color rojo mayor es la penalidad al objetivo, es decir, menos control de inundaciones, mientras que entre mas amarillo, se le da menos penalidad al objetivo y por lo tanto mas prioridad.




Figura 58. Simulación de Reglas de operación optimizadas usando función lineal para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.

5.1.4 Modelos de operación con RNA MOEA/D

Los modelos de operación con RNA también fueron corridos con el algoritmo MOEA/D de JMETALPY con el fin de compararlos con los resultados obtenidos con el NSGAI. En la figura 59 se muestran los frentes de Pareto 3D obtenidos con MOEA/D, el tiempo computacional fue de aproximadamente 8 horas para cada uno de los modelos operacionales ejecutados.

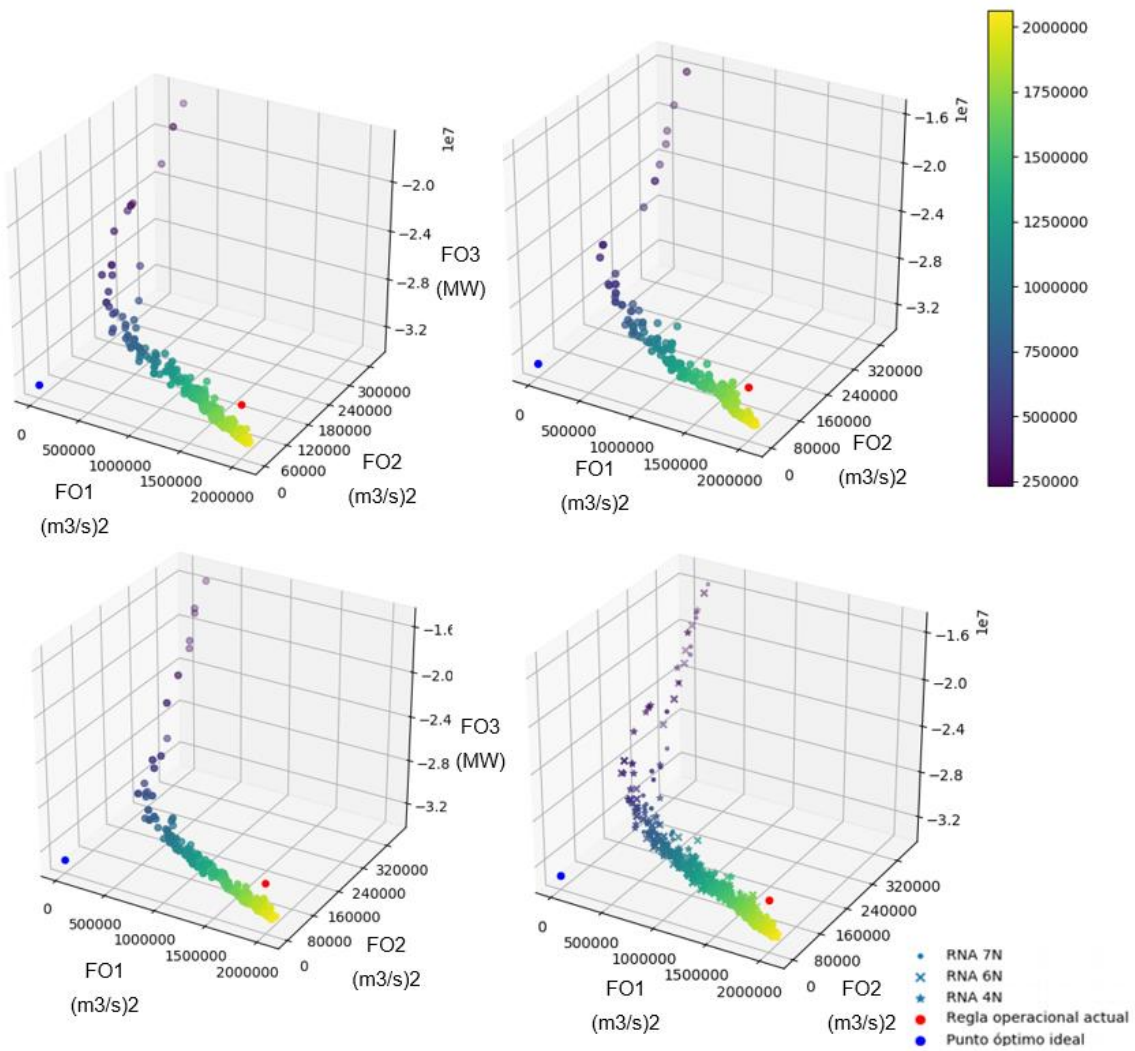


Figura 59. a) Frente Pareto RNA 7N, (b) Frente Pareto RNA 6N, (c) Frente Pareto RNA 4N, (d) Frente de Pareto combinado para los 3 modelos RNA. Utilizando MOEA/D

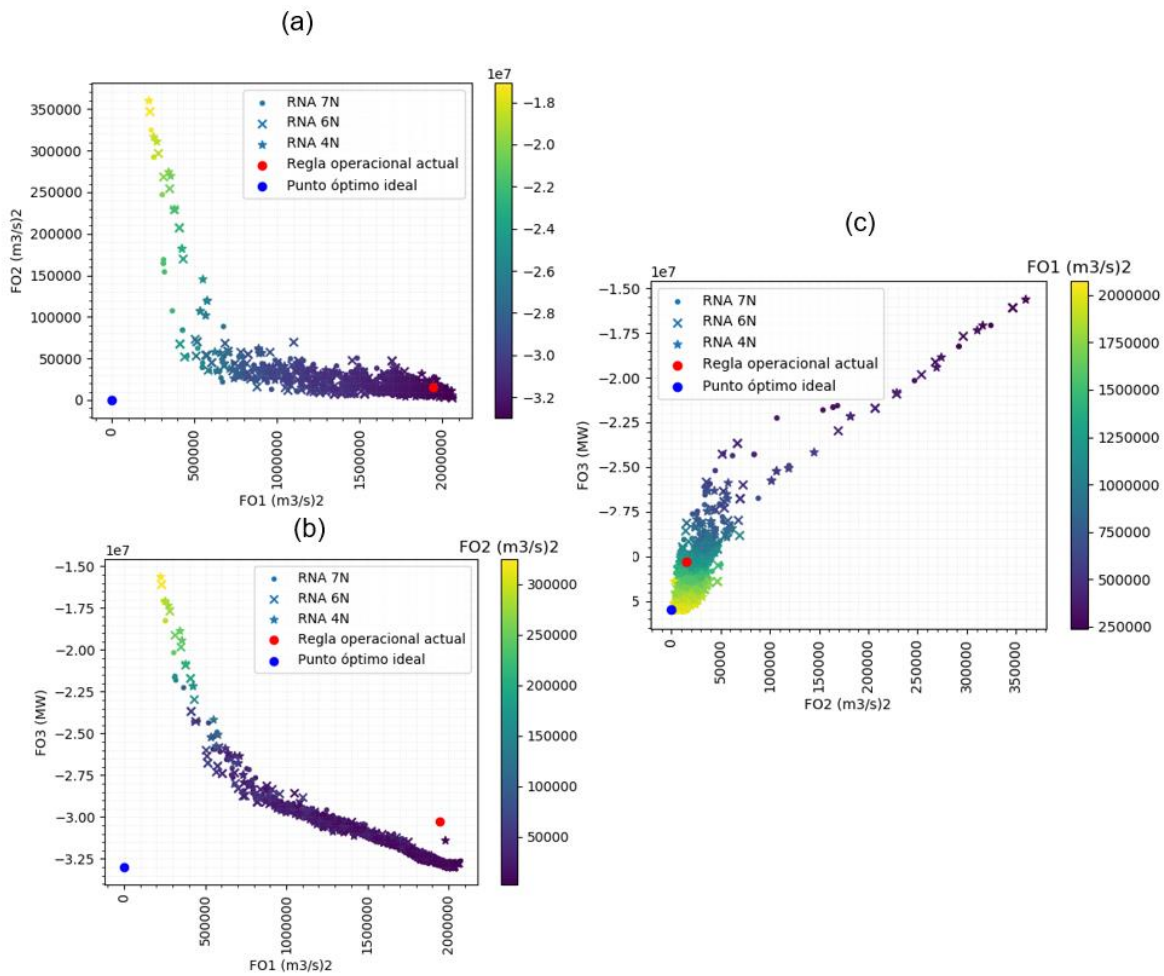


Figura 60. Frentes de Pareto para modelos de operación con RNA (a) FO1 vs FO3, (b) FO2 vs FO3, (c) FO1 vs FO2. Utilizando MOEA/D

Tabla 8. Mejores soluciones para cada uno de los objetivos de los modelos con RNA y el algoritmo MOEA/D.

MODELO OPERACIONAL	Mejores Soluciones para cada objetivo			Porcentaje mejora		
	FO1	FO2	FO3	FO1	FO2	FO3
Operación Actual	1943283	15496	-30271413	%	%	%
RN 7N	199236	2788	-32979429	Reduce a 10	Reduce a 18	Aumenta a 109
RN 6N	204306	2360	-32993057	Reduce a 11	Reduce a 15	Aumenta a 109
RN 4N	211275	3053	-32948418	Reduce a 11	Reduce a 20	Aumenta a 109




Figura 61. Hidrogramas de descarga del embalse para los modelos optimizados de RNA usando MOEA/D. Arriba se muestran los hidrogramas para todo el periodo de análisis, en el centro y abajo se muestran los mismos hidrogramas en detalle (dividido en dos segmentos de tiempo), el color relaciona los hidrogramas con las reglas de operación que los genera a partir de su ubicación en el frente de Pareto. El hidrograma azul representa las descargas reales efectuadas durante el periodo de análisis.




Figura 62. Comparación de los objetivos para las reglas de operación obtenidas usando RNA con el algoritmo MOEA/D




Figura 63. Simulación de Reglas de operación optimizadas usando RNA con el algoritmo MOEA/D para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.

El proceso de optimización para funciones de Base Radial no arrojó convergencia empleando el algoritmo MOEA/D, lo anterior debido a la alta dimensionalidad del problema.

5.1.5 Modelos de operación con función lineal MOEA/D

El modelo de operación con FL también fue corrido con el algoritmo MOEA/D de JMETALPY con el fin de compararlos con los resultados obtenidos con el NSGAI. En la figura 64 se muestra el frente de Pareto 3D obtenido con MOEA/D, el tiempo computacional fue de aproximadamente 8 horas para cada uno de los modelos operacionales ejecutados.




Figura 64. Frente de Pareto 3D para modelo de operación con función Lineal usando el algoritmo MOEA/D

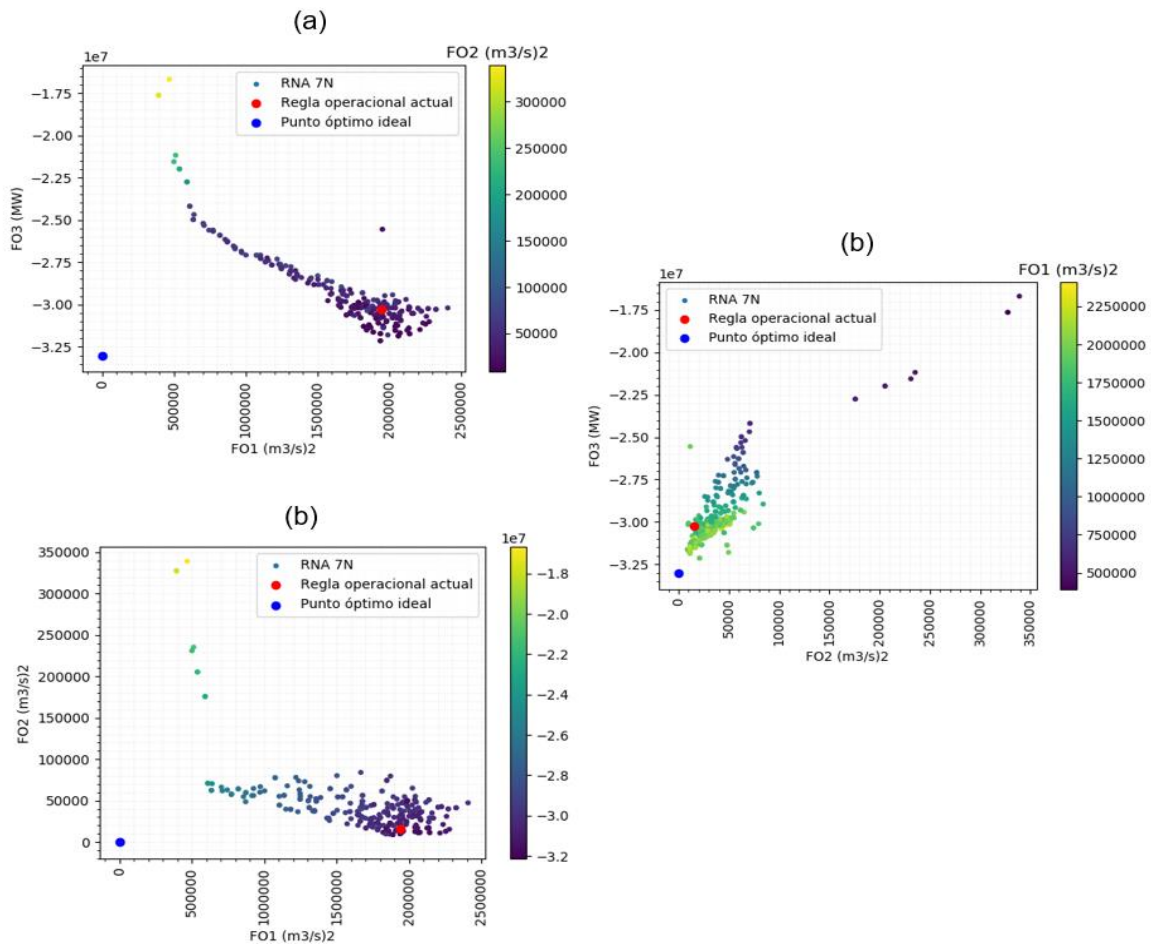


Figura 65. Frentes de Pareto para modelos de operación con FL usando el algoritmo MOEA/D; (a) FO1 vs FO3, (b) FO2 vs FO3, (c) FO1 vs FO2

En general, se observa que las funciones lineales presentan más problemas para converger a una solución óptima para este algoritmo ya que no se evidencia un patrón claro de frontera en las reglas de operación optimizadas.

Tabla 9. Mejores soluciones para cada uno de los objetivos de los modelos con función lineal y el algoritmo MOEA/D.

MODELO OPERACIONAL	Mejores Soluciones para cada objetivo			Porcentaje mejora		
	FO1	FO2	FO3	FO1	FO2	FO3
Operación Actual	1943283	15496	-30271413	%	%	%
RN 7N	392946	8930	-32137932	Reduce a 20	Reduce a 58	Aumenta a 106




Figura 66. Hidrogramas de descarga del embalse para los modelos optimizados con Función lineal y el algoritmo MOEA/D. Arriba se muestran los hidrogramas para todo el periodo de análisis, en el centro y abajo se muestran los mismos hidrogramas en detalle (dividido en dos segmentos de tiempo), el color relaciona los hidrogramas con las reglas de operación que los genera a partir de su ubicación en el frente de Pareto. El hidrograma azul representa las descargas reales efectuadas durante el periodo de análisis.




Figura 67. Comparación de los objetivos para las reglas de operación obtenidas usando función lineal y el algoritmo MOEA/D




Figura 68. Simulación de Reglas de operación optimizadas usando función lineal y el algoritmo MOEA/D para periodo húmedo. (a) Hidrogramas; (b) Niveles de operación. La línea cian representa la media de las reglas de operación optimizadas; la línea azul segmentada representa la operación real del embalse.

5.1.6 Comparación de resultados

El indicador utilizado para comparar los frentes de Pareto es el Hipervolumen. En la tabla 10 se registran los valores de este indicador obtenidos para los diferentes modelos de operación en donde se observa que el mejor resultado corresponde al modelo de operación con Redes Neuronales para la configuración de 7 Neuronas. En la figura 69 se presenta el Frente de Pareto que integra todos los resultados obtenidos para los diferentes modelos de operación. De esta figura se puede identificar claramente que las reglas de operación construidas por RNA (color rojo) son las que presentan los mejores resultados al acercarse más hacia el óptimo ideal, lo cual concuerda con el indicador del hipervolumen.




Figura 69. Frente de Pareto 3D unificado para todos los modelos de operación

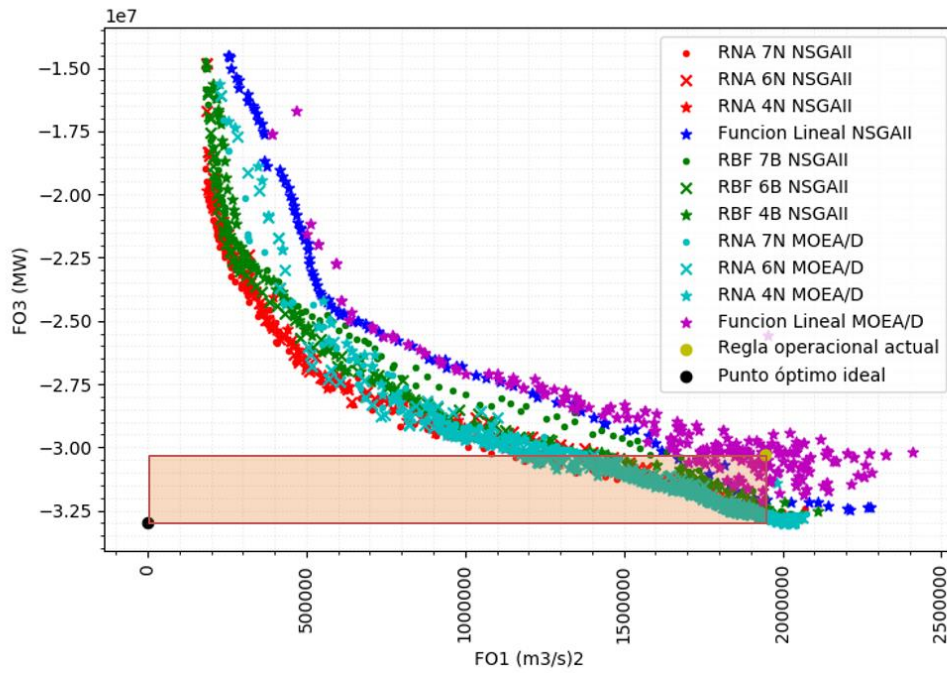


Figura 70. Frente de Pareto 2D unificado para todos los modelos de operación FO1 vs FO3




Figura 71. Frente de Pareto 2D unificado para todos los modelos de operación FO1 vs FO2




Figura 72. Frente de Pareto 2D unificado para todos los modelos de operación FO2 vs FO3

En las figuras 70, 71 y 72 se observan los frentes de Pareto 2D para todas las reglas operacionales generadas por la optimización de todos los modelos de operación, los rectángulos sombreados en rojo representan el espacio de decisión en donde se encuentra las reglas de operación que igualan o mejoran la operación actual del embalse.

Tabla 10. Valores de hipervolumen obtenidos para los diferentes modelos e operación.

Modelo de operación		Hipervolumen	
		NSGAI	MOEA/D
Función Lineal		1.06E+19	1.03E+19
RNA	4N	1.33E+19	1.26E+19
	6N	1.31E+19	1.26E+19
	7N	1.34E+19	1.26E+19
RBR	4B	1.26E+19	-
	6B	1.27E+19	-
	7B	1.19E+19	

En la figura 73 se presentan los hidrogramas de descarga para todas las reglas de operación generadas en el proceso de optimización de todos los modelos de operación, simulados para el periodo de análisis (2009-2019). Así mismo, se presentan los niveles simulados del embalse con cada una de las reglas de operación obtenidas para el mismo periodo de análisis.




Figura 73. Envolvente para hidrogramas generados por todas las reglas de operación obtenidas de la optimización. Arriba se muestran la envolvente resaltando los valores medios de las reglas de operación optimizadas, en degradado azul se indican los rangos o percentiles de la envolvente. Abajo se presentan todos los hidrogramas generados por todos los modelos optimizados.

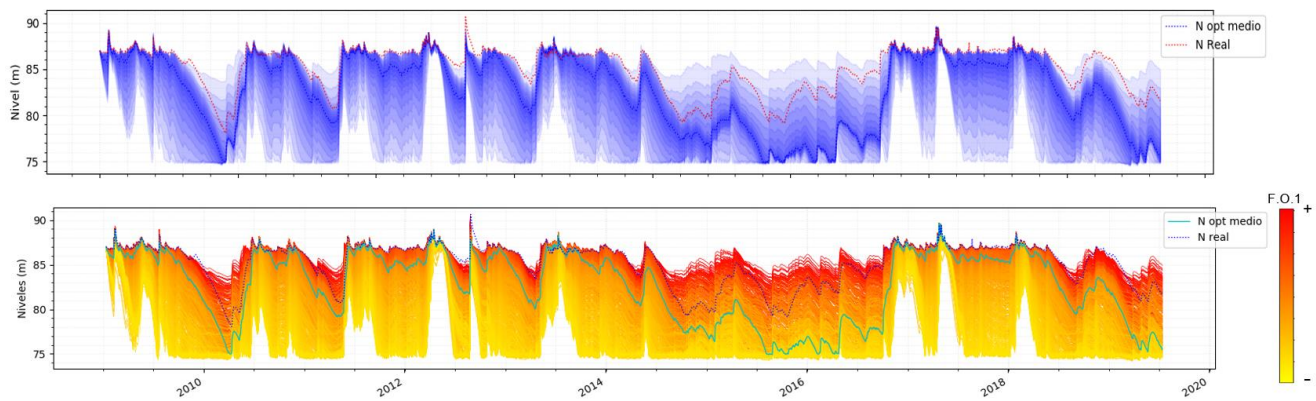


Figura 74. Envolvente para hidrogramas generados por todas las reglas de operación obtenidas de la optimización. Arriba se muestra la envolvente resaltando los valores medios de las reglas de operación optimizadas, en degradado azul se indican los rangos o percentiles de la envolvente. Abajo se presentan todos los niveles generados por todos los modelos optimizados.




Figura 75. Comparación de los objetivos para todas las reglas de operación

En la figura 75, se muestran los resultados de las reglas de operación optimizadas indicando los tres objetivos y los caudales máximos generados para toda la serie de tiempo. Los valores son normalizados de 0 a 1 con el propósito de representar en la misma escala los resultados para los tres objetivos. La línea azul segmentada refleja la evaluación de los objetivos para la operación real del embalse en el periodo de análisis (2009-2019), la línea color cian segmentada representa el promedio de las funciones objetivo para todas las reglas de operación optimizadas.

5.1.7 Selección de reglas de operación

La figura 76 corresponde a un acercamiento de la figura 71 de la zona sombreada color rojo que representa el espacio de decisión que iguala o supera las reglas de operación actuales (registradas 2009-2019) para los objetivos FO1 y FO2. A partir de este conjunto de reglas de operación, se seleccionan 2 de ellas para realizar pruebas de simulación y evaluar los hidrogramas de descarga que generan, se

toman las dos localizadas hacia el costado superior izquierdo del espacio de decisión, priorizando el objetivo FO1, estas reglas de operación corresponden al modelo operacional de RNA con 7 neuronas. Para efectos comparativos se selecciona una tercera regla de operación más inclinada hacia el costado derecho del espacio de decisión tomado (mayor equilibrio de decisión).




Figura 76. Acercamiento del frente de Pareto unificado FO1 vs FO2 para el espacio de decisión.

Así mismo, se selecciona una regla de operación localizada fuera del espacio de decisión de la figura 76, hacia el costado izquierdo de FO1, la cual brinda más prioridad a este objetivo, castigando levemente el objetivo FO2. En la figura 77 se presenta los hidrogramas de salida para las reglas de operación seleccionadas y para la regla de operación actual.




Figura 77. Hidrogramas de salida del embalse para las reglas de operación seleccionadas y la regla de operación actual.

De la figura 77 se observa que las reglas de operación optimizadas logran reducir los picos de los caudales de descarga del embalse respecto a la regla de operación actual. Si se tienen en cuenta los picos de descarga del embalse para los eventos mostrados en la figura 19 en la sección “4.3 Recolección de datos y procesamiento” se observan por ejemplo que los caudales de salida de Hatillo para eventos como la ola invernal de enero de 2018 pudieron reducirse hasta en un 50 %, en la tabla 11 se presenta la comparación de los caudales de descarga obtenidos con las reglas de operación optimizadas y la regla de operación actual para los eventos descritos en la sección 4.3.

Tabla 11. Evaluación de las reglas de operación seleccionadas en la reducción de caudales pico para los eventos extremos FO1 vs FO2.

Id	Evento	Fecha	Regla O. Actual	RN_7N_16		RN_7N_44		RN_7N_40		RN_7N_47	
			Q real (m ³ /s)	Qsal (m ³ /s)	% Qsal/Q real	Qsal (m ³ /s)	% Qsal/Q real	Qsal (m ³ /s)	% Qsal/Q real	Qsal (m ³ /s)	% Qsal/Q real
1	Ola invernal	enero de 2018	239	214	90	139	58	118	49	128	54
2	Ola invernal	abril de 2017	317	322	102	304	96	301	95	205	65
3	Ola invernal	noviembre de 2016	209	184	88	181	87	181	87	127	61
4	Tormenta tropical Chantal	julio de 2013	242	220	91	246	102	186	77	134	55
5	Tormenta tropical Isaac	agosto de 2012	217	182	84	174	80	160	74	132	61
6	Ola invernal	abril de 2012	255	277	109	277	109	277	109	235	92
7	Ola invernal	junio de 2011	204	155	76	128	63	116	57	123	60
8	Ola invernal	julio de 2010	219	191	87	131	60	117	53	125	57
9	Ola invernal	mayo de 2009	203	226	111	169	83	164	80	123	61
10	Ola invernal	febrero de 2009	270	246	91	190	70	198	73	140	52

Se puede observar que la regla de operación RN_7N_47 reduce todos los picos de los hidrogramas para los 10 eventos analizados, bajando los picos de los hidrogramas hasta en un 52 %. En la figura 78 se muestran los hidrogramas de salida del embalse para las diferentes reglas de operación durante la ola invernal del enero de 2018, en donde todas las reglas operacionales ptimizadas reducen el pico del hidrograma respecto la regla de operación actual.




Figura 78. Hidrogramas de salida del embalse para las reglas de operación seleccionadas del espacio (FO1 vs FO2) y la regla de operación actual durante el evento de enero de 2018

La regla de operación que representa los mejores resultados para el control de inundaciones es la RN_7N_47, sin embargo, esta se encuentra fuera del espacio de decisión en donde se iguala o supera el objetivo FO2, por lo tanto, la regla de operación que mejor se ajusta para el control de inundaciones sin disminuir el objetivo FO2 es la RN_7N_40.

La figura 79 por su parte corresponde a un acercamiento de la figura 72 de la zona sombreada color rojo que representa el espacio de decisión que iguala o supera las reglas de operación actuales (registradas 2009-2019), esta vez, para los objetivos FO1 y FO3. A partir de este conjunto de reglas de operación, se seleccionan también 2 de ellas para realizar pruebas de simulación y evaluar los hidrogramas de descarga que generan, estas dos están localizadas hacia el costado superior izquierdo del espacio de decisión, priorizando el objetivo FO1, estas reglas de operación también corresponden al modelo operacional de RNA con 7 neuronas.

Así mismo, se selecciona una tercera regla de operación, la cual se localiza más hacia el medio del espacio de decisión (mayor equilibrio o acuerdo).




Figura 79. Acercamiento del frente de Pareto unificado FO1 vs FO3 para el espacio de decisión




Figura 80. Hidrogramas de salida del embalse para las reglas de operación seleccionadas del espacio (FO1 vs FO3) y la regla de operación actual durante el evento de enero de 2018

Así mismo, se selecciona una regla de operación localizada fuera del espacio de decisión de la figura 79, hacia el costado izquierdo de FO1, la cual brinda más prioridad a este objetivo, castigando levemente el objetivo FO3. En la figura 80 se presentan los hidrogramas de salida para las reglas de operación seleccionadas y para la regla de operación actual.

La regla de operación que representa los mejores resultados para el control de inundaciones es la RN_7N_77, sin embargo, esta se encuentra fuera del espacio de decisión en donde se iguala o supera el objetivo FO2, por lo tanto, la regla de operación que mejor se ajusta para el control de inundaciones sin disminuir el objetivo FO3 es la RN_7N_23.




Figura 81. Hidrogramas de salida del embalse para las reglas de operación seleccionadas del espacio (FO1 vs FO2) y la regla de operación actual durante el evento de enero de 2018.

Tabla 12. Evaluación de las reglas de operación seleccionadas en la reducción de caudales pico para los eventos extremos FO1 vs FO3.

Id	Evento	Fecha	Regla O.	RN_7N_77		RN_7N_23		RN_7N_68		RN_7N_41	
			Actual	Qsal (m³/s)	% Qsal/Qreal	Qsal (m³/s)	% Qsal/Qreal	Qsal (m³/s)	% Qsal/Qreal	Qsal (m³/s)	% Qsal/Qreal
1	Ola invernal	enero de 2018	239	230	96	197	82	130	54	215	90
2	Ola invernal	abril de 2017	317	318	101	311	98	231	73	320	101
3	Ola invernal	noviembre de 2016	209	240	115	239	115	134	64	180	86
4	Tormenta tropical Chantal	julio de 2013	242	213	88	220	91	141	58	218	90
5	Tormenta tropical Isaac	agosto de 2012	217	190	87	172	79	150	69	197	91
6	Ola invernal	abril de 2012	255	276	108	276	108	236	93	276	108

7	Ola invernal	junio de 2011	204	134	66	142	70	123	60	168	82
8	Ola invernal	julio de 2010	219	137	63	131	60	126	57	199	91
9	Ola invernal	mayo de 2009	203	209	103	187	92	125	61	216	106
10	Ola invernal	febrero de 2009	270	246	91	242	90	139	52	255	95

5.1.7.1 Mancha de inundación

Con el propósito de evaluar los efectos de la descarga del embalse en las zonas aguas abajo, se realizó un modelo hidráulico en el software IBER para calcular la mancha de inundación generada por la regla de operación RN_7N_47. Es importante destacar que dicho modelo fue elaborado a partir de un modelo de elevación digital con una resolución de imagen de 12.5 m x 12.5. Por lo tanto, con las limitaciones que esto implica debe considerarse tan solo como una aproximación del impacto que generaría la descarga del embalse en las zonas aguas abajo.

En la figura 82, se muestra la mancha de inundación generada por la descarga del embalse para la regla de operación actual durante el evento de la ola invernal de abril de 2017. Por su parte la figura 83 muestra la mancha de inundación que genera la regla de operación RN_7N_47 para el mismo evento.

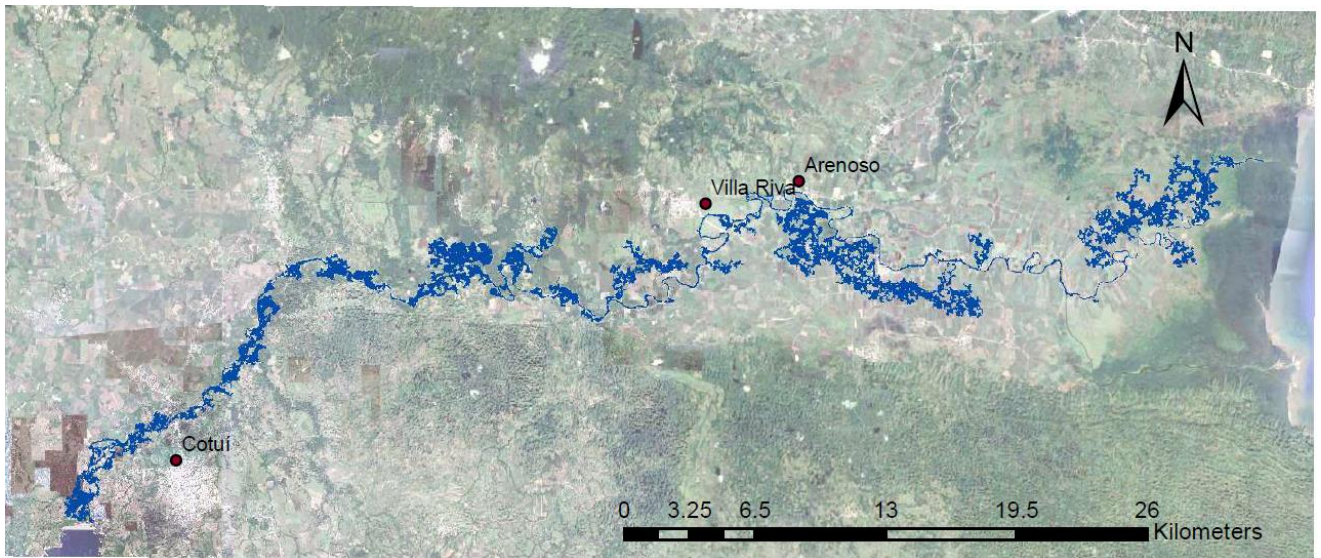


Figura 82. Simulación de Mancha de inundación con las reglas de operación actual del embalse para la ola invernal de abril de 2017




Figura 83. Simulación de Mancha de inundación con la regla de operación RN_7N_47 para la ola invernal de abril de 2017




Figura 84. Simulación de Mancha de inundación con la regla de operación RN_7N_47 (mancha roja) y con la regla de operación actual para la ola invernal de abril de 2017 aguas debajo del embalse

La mancha roja en la figura 84 representa el nivel de la lámina para la descarga del embalse con la regla de operación optimizada, la mancha azul por su parte corresponde al nivel del agua para el caudal de descarga con la regla de operación actual.

5.1.8 Validación de resultados

A partir de la serie sintética de caudales de entrada, se evalúa el desempeño de tres diferentes reglas de operación optimizadas; Para este ejercicio se realiza la simulación de la regla de operación RN_7N_40, la RN_7N_47 y la RN_7N_16, y se comparan con la regla de operación actual obtenida para el periodo (2009-2019) la cual corresponde a la red neuronal obtenida en el capítulo 4.4.2.1. La figura 85 muestra los hidrogramas de descarga del embalse obtenidos tanto para las reglas optimizadas como para la regla de operación actual.




Figura 85. Hidrogramas de salida del embalse para las reglas de operación optimizadas y la regla de operación actual para el caudal pico más alto de la serie sintética.

La figura 86 muestra un acercamiento de la figura 85 en donde se muestra el pico de descarga más alto registrado para la serie sintética generado por la regla de operación actual.




Figura 86. Hidrogramas de salida del embalse para las reglas de operación optimizadas y la regla de operación actual para el caudal pico de la serie sintética

Tabla 13. Evaluación de las reglas de operación seleccionadas en la reducción de caudales pico para los eventos extremos. Serie sintética.

	Qsal (m ³ /s)	% Qsal/Qreal
Regla de operación actual	270	100
RN_7N_40	219	81
RN_7N_16	219	81
RN_7N_47	196	72

Como resultado se observa que las reglas de operación optimizadas permiten reducir los picos del hidrograma de descarga que generaría la regla de operación actual tal como se observa en la figura 86 con una reducción de hasta el 28% para la regla RN_7N_47.

6 CONCLUSIONES Y RECOMENDACIONES

Los resultados del presente estudio demuestran que es posible reducir los picos de los hidrogramas de descarga del embalse de Hatillo, y, por lo tanto, reducir la magnitud de las inundaciones aguas abajo. Lo anterior mediante la adopción de reglas de operación óptimas que fueron obtenidas bajo un enfoque multiobjetivo, considerando, además, el suministro de agua para riego y la generación Hidroeléctrica.

Las reglas de operación del embalse se pueden parametrizar utilizando algoritmos de aprendizaje como las redes Neuronales Artificiales. Como resultado de este estudio se encontró que estos métodos pueden replicar de forma precisa los patrones o políticas que rigen la operación del embalse.

Queda claro que los propósitos de reducción de inundaciones, suministro de agua para riego y generación hidroeléctrica entran en conflicto en la toma de decisiones para la operación del embalse, sin embargo, se encontró mediante el uso de funciones de aproximación y técnicas de optimización multiobjetivo que es posible obtener un espacio de decisión, del cual, se puedan convenir reglas de operación que permitan llegar a un equilibrio en la toma de decisiones teniendo en cuenta los tres intereses de operación. Los resultados muestran que las reglas de operación actual o con la cual se operó el embalse durante el periodo 2009 – 2019, están orientadas principalmente al cumplimiento de los propósitos de generar energía eléctrica y suministrar agua para riego.

Para el caso concreto de evaluar la posibilidad de reducir las inundaciones en el Bajo Yuna mediante un manejo óptimo del embalse, se identificaron múltiples reglas de operación que pueden reducir los caudales máximos de descarga de la presa disminuyendo así el impacto de eventos extremos; Se encontraron reglas de operación que reducen los picos de descarga del embalse igualando o incluso mejorando los objetivos de suministro de agua para riego y generación hidroeléctrica respecto a la regla de operación actual. También, se identificaron reglas de operación que permiten reducir aún más los caudales pico de descarga de la presa sin afectar sustancialmente los demás propósitos; Adicionalmente, se encontraron reglas de operación que redujeron aproximadamente a la mitad los picos de descarga del embalse, lo cual implica, sin embargo, una mayor afectación a los otros

objetivos. En este contexto, y dado los problemas de inundaciones que se han presentado en el bajo Yuna, se considera que las reglas de operación del embalse deben estar enfocadas en la reducción de los caudales pico de descarga del embalse sin afectar considerablemente los demás propósitos, para lo cual se pueden usar reglas de operación como la RN_7N_47 o la RN_7N_40.

Por otra parte, se pudo observar que los modelos de operación de embalses se pueden parametrizar adecuadamente empleando funciones de aproximación como las Redes Neuronales o Redes de Base Radial, lo anterior en la medida de que ambos pueden replicar patrones o formas complejas que normalmente no pueden ser construidas por otras funciones. Los resultados de la optimización de todos los modelos demuestran que la Redes Neuronales artificiales se ajustan mejor respecto a los otros métodos. Siendo el NSGAI el algoritmo de optimización que mejor desempeño tuvo en términos de tiempo computacional y resultados.

Se recomienda para futuros trabajos, involucrar dentro de los modelos de operación variables de tipo económico que permitan evaluar la operación del embalse directamente en términos de costos para la toma de decisiones.

Así mismo, se recomienda evaluar el desempeño de los modelos de operación involucrando pronósticos de caudales de entrada para el embalse, así como la incorporación de datos de precipitaciones como variables de entrada para los modelos.

Bibliografía

- Ahmadian, A. S. (2016). Numerical Modeling and Simulation. En A. S. Ahmadian, *Numerical Models for Submerged Breakwaters* (págs. 109-126). London: Butterworth-Heinemann.
- Ahmed, J. A., & Sarma, A. K. (2007). Artificial neural network model for synthetic streamflow. *Water Resour Manage*, 1015–1029.
- Arreguín Cortés, F. I., & Marengo Mogollón, H. (2016). Las inundaciones en un marco de incertidumbre climática. *Tecnología y Ciencias del Agua*, 5-13.
- Barros, M., Tsai, F., Yang, S.-I., & Lopes, J. (2003). Optimization of large-scale hydropower system operations. *JOURNAL OF WATER RESOURCES PLANNING AND MANAGEMENT. ASCE*, 178-188.
- Benítez-Hidalgo, A., Nebro, A., García-Nieto, J., & Oregi, I. (December 2019). jMetalPy: A Python framework for multi-objective optimization with metaheuristics. *Swarm and Evolutionary Computation. Elsevier*, 12.
- Butcher, W. S. (1971). STOCHASTIC DYNAMIC PROGRAMMING FOR OPTIMUM RESERVOIR OPERATION. *Water Resources Bulletin (Journal of the American Water Resources Association)*, 115-123.
- Cai, X., McKinney, D. C., & Lasdon, L. S. (2001). Solving nonlinear water management models using a combined genetic algorithm and linear programming approach. *Advances in Water Resources*, 667-676.
- Castelletti, A., Pianosi, F., Quach, X., & Soncini-Sessa, R. (2011). Assessing water resources management and development in Northern Vietnam. *Hydrol. Earth Syst. Sci. Discuss.*, 7177–7206.
- Ceballos Bernal, A. I., Baró Suárez, J. E., & Díaz Delgado, C. (2016). ESTIMACIÓN DE PÉRDIDAS ECONÓMICAS DIRECTAS PROVOCADAS POR INUNDACIÓN. APLICACIÓN DE LAS CURVAS INUNDACIÓN-DAÑOS EN PAÍSES EN DESARROLLO. *Investigaciones Geográficas*, 169-180.

- CEPAL. NACIONES UNIDAS. (2008). *EVOLUCIÓN DEL IMPACTO DE LA TORMENTA NOEL EN REPÚBLICA DOMINICANA*. México: LC/MEX7L.853.
- Cevallos Ampuero, J. (2008). Redes Neuronales de Base Radial. *Revista de la Facultad de Ingeniería Industrial UNMSM*, 63-72.
- Chandramouli, V., & Raman, H. (2001). Multireservoir modeling with dynamic programming and neural networks. *Journal of Water Resources Planning and Management*, 89-98.
- Correa Flórez, C. A., Bolaños, R. A., & Molina Cabrera, A. (2008). ALGORITMO MULTIOBJETIVO NSGA-II APLICADO AL PROBLEMA DE LA MOCHILA. *Scientia et Technica Año XIV*, 206-211.
- Corzo Perez, G. A. (2009). *Hybrid models for hydrological forecasting: Integration of data-driven and conceptual modelling techniques*. Delft, The Netherlands.
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan. (2002). A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. *IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION*, 182-197.
- Ehsani, N., Fekete, B. M., Vörösmarty , C. J., & Tessler, Z. D. (2016). A neural network based general reservoir operation scheme. *Stoch Environ Res Risk Assess*, 1151–1166.
- Ehsani, N., Fekete, B., Vörösmarty , C. J., & Tessler, Z. D. (2016). A neural network based general reservoir operation scheme. *Stoch Environ Res Risk Assess*, 1151–1166.
- Emanueli Gandara, C. (2017). *Exploring spatial-temporal data driven modelling techniques for flow forecasting*. Delft.
- FAO. (2006). *ESTUDIO FAO RIEGO Y DRENAJE. Guías para la determinación de los requerimientos de agua de los cultivos*. Roma : FAO.
- Ferrada, L. (2012). *DISEÑO DE RODETE DE TURBINA HIDRÁULICA TIPO PELTON PARA MICROGENERACIÓN*. Santiago.

- Foundation for Water Research. (2010). *World Water: Resources, Usage and the role of man-made reservoirs*. U.K.: Foundation for Water Research.
- French, M. N., Krajewski, W. F., & Cuykendall, R. R. (1992). Rainfall forecasting in space and time using a neural network. *Journal of Hydrology*, 1-31.
- Giuliani, M., Castelletti, A., Pianosi, F., Mason, E., & Reed, P. M. (2016). Curses, Tradeoffs, and Scalable Management: Advancing Evolutionary Multiobjective Direct Policy Search to Improve Water Reservoir Operations. *ASCE, JOURNAL OF WATER RESOURCES PLANNING AND MANAGEMENT*, 04015050-1 - 04015050-17.
- Giuliani, M., Herman, J. D., Castelletti, A., & Reed, P. (2014). Many-objective reservoir policy identification and refinement to reduce policy inertia and myopia in water management. *Water Resour. Res.*, 50, 3355–3377.
- Guerreiro, A. P., Fonseca, C. M., & Paquete, L. (2005). *The Hypervolume Indicator: Problems and Algorithms*. Obtenido de ArXiv.
- Hiew, K. (1987). *OPTIMIZATION ALGORITHMS FOR LARGE-SCALE MULTIRESERVOIR HYDROPOWER SYSTEMS*. Colorado State University: Ph.D. dissertation.
- Hilera, J., & Martínez, V. (2000). *Redes Neuronales Artificiales y aplicaciones. Fundamentos, modelos y aplicaciones*. México D.F.: ALFAOMEGA.
- Ishibuchi, H., Doi, K., & Nojima, Y. (2016). Reference point specification in MOEA/D for multi-objective and many-objective problems. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 004015-004020, doi: 10.1109/SMC.2016.7844861.
- Karamouz, M., Houck, M., & Delleur, J. (1992). Optimization and Simulation of Multiple Reservoir Systems. *Journal of Water Resources Planning and Management*, 71-81.
- Karunanithi, N., Grenney, W. J., Whitley, D., & Bovee, K. (1994). Neural Networks for River Flow Prediction. *Journal of Computing in Civil Engineering*, 201-220.

- Koutsyiannis, D., & Economou, A. (2003). Evaluation of the parameterization-simulation-optimization approach for the control of reservoir systems. *WATER RESOURCES RESEARCH*, 1-17.
- Labadie, J. W. (2004). Optimal operation of multireservoir systems: State-of-the-art review. *Journal of Water Resources Planning and Management*, 93-111.
- Loucks, D., & van Beek, E. (2017). *Water Resource Systems Planning and Management*. Gewerbestrasse, Switzerland: Springer.
- MINISTERIO DE MEDIO AMBIENTE Y RECURSOS NATURALES. (23 de 07 de 2020). Yuna. Obtenido de Descripción Biofísica Subcuenca Río Yuna: <https://ambiente.gob.do/cuencas-hidrograficas/yuna-camu/>
- Momtahn, S., & Dariane, A. (2007). Direct Search Approaches Using Genetic Algorithms for Optimization of Water Reservoir Operating Policies. *ASCE, JOURNAL OF WATER RESOURCES PLANNING AND MANAGEMENT*, 202-209.
- Moquete, C. (2004). *Generalidades del Cultivo de Arroz*. Santo Domingo: IDIAF.
- National Oceanic and Atmosphere Administration. (15 de Julio de 2020). *El Niño Southern Oscillation (ENSO)*. Obtenido de <http://www.esrl.noaa.gov/psd/enso/>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., . . . Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 2825-2830.
- Raman, H., & Chandramouli, V. (1996). DERIVING A GENERAL OPERATING POLICY FOR RESERVOIRS USING NEURAL NETWORK. *J. Water Resour. Plann. Manage. ASCE.*, 122(5): 342-347.
- Reyes-Hernández, N., Ponsich, A., & Hoyos-Reyes, L. F. (2018). Técnicas metaheurísticas de optimización multiobjetivo para resolver el problema del portafolio de inversión. *Estocástica: Finanzas y Riesgo*, 149-182.
- Ritter, J. (2016). Optimisation of hydropower dam cascade operations with respect to energy generation, flood hazard and flow regime alteration using operational modelling. 9.

- Robinson, H. (2009). *Flood Prediction using Distributed Hydrologic Modeling in the Dominican Republic*. Rice University Houston, Texas: MSc Thesis.
- Rosenstein, M., & Barto, A. (2001). Robot Weightlifting By Direct Policy Search. *International Joint Conference on Artificial Intelligence*, 1-6.
- Rumelhart, D., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagation errors. *Letters to Nature*, 533-536.
- Saavedra, O. C., Koike, T., Yang, K., & Yang, D. (2010). Optimal Dam Operation during Flood Season Using a Distributed Hydrological Model and a Heuristic Algorithm. *JOURNAL OF HYDROLOGIC ENGINEERING ASCE*, 580-586.
- Sharif, M., & Wardlaw, R. (2000). Multireservoir Systems Optimization Using Genetic Algorithms: Case Study. *Journal of Computing in Civil Engineering*, 255-263.
- Stedinger, J. R., Sule, B., & Loucks, D. (1984). Stochastic dynamic programming models for reservoir operation optimization. *Water Resources Research*, 1499-1505.
- Torabi, M., & Mobasheri, F. (1974). A stochastic dynamic programming model for the optimum operation of a multipurpose reservoir. *Journal of the American Water Resources Association*, 1089-1099.
- Wurbs, R. A. (1993). Reservoir-system simulation and optimization models. *Journal of Water Resources Planning and Management*, 455-472.
- Yakowitz, S. (1982). Dynamic programming applications in water resources. *Water Resources Research*, 673-696.
- Zhang, D., Lin, J., Peng, Q., Wang, D., Yang, T., Sorooshian, S., . . . Zhuang, J. (2018). Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm. *ELSEVIER, Journal of Hydrology*, 720–736.
- Zhang, Q., & Li, H. (Dec. 2007). MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition. *IEEE Transactions on Evolutionary Computation*, vol. 11, no. 6, pp. 712-731.

ANEXOS

Anexo 1. Código Modelos de operación (Programación en Python)